



Puistopuiden kartoitustarkkuuden parantaminen puoliautomaattisesti tuotetulla latvuskartalla

Antti Mäkinen

Maisterintutkielma

Helsingin yliopisto

Metsätieteiden maisteriohjelma

Metsien ekologia ja käyttö

Marraskuu 2020



Tiedekunta – Fakultet – Faculty Maatalous-metsätieteellinen tiedekunta		Koulutusohjelma – Utbildningsprogram – Degree Programme Metsien ekologia ja käyttö	
Tekijä – Författare – Author Antti Mäkinen			
Työn nimi – Arbetets titel – Title Puistopuiden kartoitustarkkuuden parantaminen puoliautomaattisesti tuotetulla latvuskartalla			
Oppiaine/Opintosuunta – Läroämne/Studieinriktning – Subject/Study track Metsänarvioimistiede ja geoinformatiikka			
Työn laji – Arbetets art – Level Maisterin tutkielma		Aika – Datum – Month and year Marraskuu 2020	Sivumäärä – Sidoantal – Number of pages 52
Tiivistelmä – Referat – Abstract			
<p>Kaupunkipuut ja -metsät ovat tärkeitä niin ihmisen hyvinvoinnin kuin luonnon monimuotoisuuden kannalta. Kaupunkipuut parantavat ilmanlaatua, pienentävät tulvariskiä ja tarjoavat maisema ja virkistys arvoja. Kaupunkipuilla on myös negatiivisia vaikutuksia. Läkää ja huonokuntoiset tai myrskyssä kaatuvat puut voivat aiheuttaa vaaraa ja tiheät ja varjoiset metsäalueet voidaan kokea turvattomiksi. Kaupunkipuut vaativat intensiivistä hoitoa ja niiden kuntoa on tarkkailtava jatkuvasti. Kaupunkipuiden hyötyjen maksimointi ja haittojen ja kustannusten minimointi edellyttää yksityistä tiedonkeruuta kaupunkialueen puista ja tämän vuoksi monet kunnat ja kaupungit ylläpitävät puurekisteriä, jossa on tarkat tiedot yksittäisistä kaupunkipuista. Perinteisesti puurekisterin tietoja on kerätty ja päivitetty maastomittauksin, mikä on työlästä ja kallista. Uudet kaukokartoitus menetelmät ovat tarjonneet mahdollisuuden puurekisterin automaattiseen tiedon keruuseen ja päivittämiseen ja laserkeilausmenetelmien tutkimus ja hyödyntäminen kaupunkipuiden kartoituksessa ja seurannassa ovat olleet viime vuosina nopeassa kasvussa.</p> <p>Tämän tutkimuksen tavoitteena oli selvittää, onko puistopuiden kartoitustarkkuutta mahdollista parantaa puoliautomaattisella tuotetulla latvuskartalla. Työssä tuotettiin ALS-aineistosta automaattisella latvussegmentointimenetelmällä yksityiskohtainen puiden latvuskartta. Latvuskartan luonnissa puiden latvukset rajattiin valuma-aluesegmentoinnilla latvuston pintamallista. Tätä automaattisen menetelmän tuottamaa latvussegmentointia muokattiin visuaalisesti ortoilmakuvia apuna käyttäen ja virheellisesti rajautuneita latvussegmenttejä korjailtiin. Muokkauksen tuloksena saatiin uusi puolautomaattisella menetelmällä tuotettu latvussegmentointi. Automaattisen ja puolautomaattisen latvussegmentointimenetelmän tuloksia vertailtiin määrittämällä puiden havaitsemistarkkuus ja puiden läpimitan mallinnustarkkuus. Tuloksia verrattiin maastossa mitattujen puiden määrään ja läpimittoihin, jolloin saatiin tietoa menetelmien paremmuudesta. Läpimittojen mallinnuksessa käytettiin ei-parametrinen random forest -menetelmää ja lähimmän naapurin (kNN) menetelmää.</p> <p>Tutkimusalueena oli yhdeksän Helsingin sairaala-alueita, joiden yhteenlaskettu pinta-ala oli 47,2 ha ja maastossa mitattuja puita oli yhteensä 4365 ja 37 eri puulajia. Automaattinen menetelmä tuottama puumäärä oli 57,2 %:n yliarvio ja puolautomaattinen menetelmä 19,5 %:n aliarvio referenssipuumäärään nähden. Suurimmillaan yliarvio automaattisella menetelmällä oli Koskelan tutkimusalueella (221,6 %) ja pienimmän aliarvion tuotti puolautomaattinen menetelmä Suursuon tutkimusalueella (75,5 %). Automaattinen menetelmä tuottamista latvussegmenteistä 63 % oli komissiovirheitä ja puolautomaattisen menetelmän latvussegmenteistä 33 % oli komissiovirheitä. Läpimitaennusteiden suhteellinen RMSE oli automaattisella menetelmällä 41,8 % ja puolautomaattisella 35,8 %. Läpimitaennusteet tarkentuivat koko aineistolla 6 %-yksikköä ja neljän yleisimmän puulajin kohdalla 7 %-yksikköä.</p> <p>Tutkimuksen tulokset osoittivat, että ALS-aineistosta yksinpuintulkintamenetelmällä automaattisesti tuotettua latvuskartan tarkkuutta pystyttiin parantamaan puolautomaattisella menetelmällä. Puiden kartoitustarkkuus parani sekä puiden havaitsemistarkkuuden, että läpimitan mallinnustarkkuuden osalta. Tutkimuksen tulosten perusteella voidaan todeta puolautomaattisen menetelmän olleen käyttökelpoinen etenkin puistoissa alueilla, mutta tiheäpuustoissa metsäalueilla siitä ei ollut merkittävää hyötyä. Tämän tutkimuksen perusteella voidaan todeta, että tässä työssä käytetty puolautomaattinen puiden kartoitusmenetelmä voisi olla hyödyllinen operatiivisessa kaupunkipuiden kartoituksessa ja seurannassa erityisesti puistoissa alueilla.</p>			
Avainsanat – Nyckelord – Keywords Kaupunkipuu, lentolaserkeilaus, yksinpuintulkinta, kaupunkipuiden kartoitus, random forest, kNN			
Ohjaaja tai ohjaajat – Handledare – Supervisor or supervisors Topi Tanhuanpää, Ville Luoma			
Säilytyspaikka – Förvaringsställe – Where deposited HELDA - Helsingin yliopiston digitaalinen arkisto / HELDA - Helsingfors universitets digitala publikationsarkiv / HELDA - Digital Repository of the University of Helsinki			
Muita tietoja – Övriga uppgifter – Additional information			



Tiedekunta – Fakultet – Faculty Faculty of Agriculture and Forestry		Koulutusohjelma – Utbildningsprogram – Degree Programme Forest ecology and Management
Tekijä – Författare – Author Antti Mäkinen		
Työn nimi – Arbetets titel – Title Improving the accuracy of urban tree mapping with a semi-automatically produced canopy map		
Oppiaine/Opintosuunta – Läroämne/Studieinriktning – Subject/Study track Forest resources management and Geo-informatics		
Työn laji – Arbetets art – Level Master's thesis	Aika – Datum – Month and year November 2020	Sivumäärä – Sidoantal – Number of pages 52
Tiivistelmä – Referat – Abstract <p>Urban trees and forests are important for human well-being and the diversity of urban nature. Urban forests maintain biodiversity, improve air quality and offer aesthetic and recreational value. The urban trees have also some negative effects. Trees in bad condition can cause harm or danger to humans property. Dense and shady urban forests may cause feelings of insecurity and tree pollen can cause health problems. The urban trees require intensive management and their condition must be constantly monitored. Maximizing the benefits of urban trees and minimizing disadvantages requires detailed data on urban trees. For this reason, many municipalities and cities maintain a tree register with accurate information on individual city trees. Traditionally, data on urban trees have been collected and updated by field surveys, which is laborious and expensive. New laser scanning methods that produce accurate three-dimensional information offer the opportunity to automatically update the tree register. Interest in utilizing them in urban tree mapping and monitoring has been growing rapidly in recent years.</p> <p>This thesis studied ALS-based individual tree detection methods in urban tree mapping. The aim of this study was to determine whether the accuracy of the automatically generated canopy map from ALS-data could be improved by a semi-automatic method. Initially, a detailed canopy map of trees was produced by automated method. Tree candidates were delineated from the surface model by utilizing watershed segmentation. The canopy segmentation produced by the automated method was visually modified and incorrectly delimited canopy segments were corrected. This resulted in a semi-automatically produced canopy map. The results of the automatic and semi-automatic canopy segmentation method were compared by determining the detection accuracy of the trees and the modeling accuracy of the tree diameter. The results were compared with the number and the diameter of trees measured in the field. Non-parametric random forest method and the nearest neighbor (kNN) method were used in the diameter modeling process.</p> <p>The study area consisted of nine Helsinki hospital areas with a total area of 47,2 ha. There were 4365 trees and 37 different tree species measured in the field. The automatic method produced 6860 trees and the semi-automatic method produced 3500 trees. Thus, the automatic method produced an overestimation of 57.2% and the semi-automatic method produced an underestimation of 19.5 % compared to the reference trees. The largest overestimation by the automatic method was in the Koskela study area (221.6 %) and the smallest underestimation was produced by the semi-automatic method in the Suursuo study area (75.5 %). 63 % of the canopy segments produced by the automatic method were commission errors and 33% of the canopy segments produced by semi-automatic method were commission errors. With the automatic method, the absolute RMSE of the diameter prediction was 12,84 cm and 10,99 cm with semi-automatic method. The diameter predictions of the whole data were 6 % more accurate with the semi-automatic method.</p> <p>The results of the study showed that the accuracy of the automatically generated canopy map from the laser scanning data can be improved by the semi-automatic method. Tree mapping accuracy improved in terms of both tree detection accuracy and diameter modeling accuracy. Based on the results of the study, it can be stated that the semi-automatic method is useful especially in parkland areas, but in densely wooded forest areas there is still issues to solve make this method practical. The benefits of a semi-automated method should be assessed by comparing the workload with the results. Based on this study, the semi-automatic individual tree detection method used in this work could be useful in the operational mapping and monitoring of urban trees.</p>		
Avainsanat – Nyckelord – Keywords urban tree, airborne laser scanning, individual tree detection, urban tree register, random forest, kNN		
Ohjaaja tai ohjaajat –Handledare – Supervisor or supervisors Topi Tanhuanpää, Ville Luoma		
Säilytyspaikka – Förvaringställe – Where deposited HELDA - Helsingin yliopiston digitaalinen arkisto / HELDA - Helsingfors universitets digitala publikationsarkiv / HELDA - Digital Repository of the University of Helsinki		
Muuta tietoa – Övriga uppgifter – Additional information		

Sisällysluettelo

1 JOHDANTO	7
1.1 Tutkimuksen tausta	7
1.2 Kaupunkipuun määritelmä.....	8
1.3 Kaupunkipuiden seuranta ja kartoitus.....	8
1.4 Laserkeilaus	9
1.4.1 Lentolaserkeilaus	10
1.4.2 ALS-aineiston prosessointi yksinpuintulkinnassa	12
1.4.3 Pintamallimenetelmät	12
1.4.4 3D-Menetelmät	13
1.4.5 Kaupunkipuiden yksinpuintulkinta.....	14
1.5 Tutkimuksen tavoitteet ja tutkimusongelma	16
2 AINEISTO JA MENETELMÄT.....	17
2.1 Tutkimusalue.....	17
2.2 Maastoaineisto	18
2.3 Laserkeilausaineisto.....	19
2.4 Latvuston pintamallin prosessointi	20
2.4.1 Latvuston pintamallin suodatus	20
2.3.2 Automaattinen latvussegmentointi.....	21
2.3.3 Puoliautomaattinen latvussegmentointi	22
2.5 Automaattisen ja puoliautomaattisen menetelmän tarkkuuden arviointi	23
2.5.1 Puiden havaitsemistarkkuuden arviointi.....	23
2.5.2 Läpimittaennusteiden tarkkuuden arviointi	25
3 TULOKSET	27
3.1 Puiden havaitsemistarkkuus.....	27
3.2 Läpimittaennusteiden tarkkuus	31
4 TULOSTEN TARKASTELU	35
4.1 Puiden havaitsemistarkkuuden tarkastelu	35
4.2 Läpimittaennusteiden tarkkuuden tarkastelu	39
4.3 Puoliautomaattisen latvussegmentointimenetelmän tarkastelu.....	42
4.4 Tutkimuksen mahdollisia virhelähteitä	43
5 JOHTOPÄÄTÖKSET.....	44
6 LÄHTEET.....	45
LIITTEET	51

Kiitokset

Tämä tutkimus on tehty yhteistyössä Helsingin kaupungin kanssa ja haluan kiittää onnistuneesta yhteistyöstä ja tutkimuksen rahoituksesta.

Erityisesti haluan osoittaa kiitokset Topi Tanhuanpäälle ja Ville Luomalle korvaamattomasta ja kannustavasta ohjauksesta. Lisäksi haluan kiittää Markus Holopaista arvokkaista kommentteista liittyen tutkimussuunnitelmaan ja tuloseseminaariin.

Lopuksi vielä kiitos perheelle ja ystäville kannustuksesta sekä avusta työn oikoluvussa.

Helsingissä 16.11.2020

Antti Mäkinen

LYHENTEET

ALS	(Airborne Laser Scanning) - Lentolaserkeilaus
CHM	(Canopy Height Model) - Latvuston korkeusmalli
DCM	(Digital Canopy Model) - Latvuston pintamalli
DGPS	(Differential Global Positioning Systems) - GPS-paikannuksen alueellinen tarkennusmenetelmä.
DTM	(Digital Terrain Model) - Maan pintamalli
GPS	(Global Positioning System) - Yhdysvalloissa kehitetty satelliittipaikannusjärjestelmä
IMU	(Inertial Measurement Unit) - 6-ulotteinen sensorin asentoa, paikkaa ja liikettä mittaava järjestelmä
ITD	(Individual Tree Detection) - Yksinpuintulkinta
MLS	(Mobile Laser Scanning) - Maastolaserkeilaus
TLS	(Mobile Laser Scanning) - Liikkuva maastolaserkeilaus

1 JOHDANTO

1.1 Tutkimuksen tausta

Kaupunkimetsät, puistot ja viheralueet ovat tärkeitä niin ihmisen hyvinvoinnin kuin luonnon monimuotoisuuden kannalta ja tarjoavat monenlaisia hyötyjä kaupunkilaisille. Kaupunkimetsät ja -puut tarjoavat eri lajeille monipuolisia elinympäristöjä, ravintoa ja suojaa ja edistävät näin luonnon monimuotoisuutta (Gómez-Baggethun ym. 2013). Puut parantavat kaupungin ilmanlaatua, pienentävät tulvariskiä ja viilentävät ympäristöä varjostamalla ja haihduttamalla (Bolund ja Hunhammar 1999). Kaupunkipuut toimivat myös hiilensitojina ja hillitsevät näin osaltaan ilmastonmuutosta (Daily ym. 1997). Kaupunkimetsät ja -puistot luovat asukkaille maisema- ja virkistysarvoja sekä lisäävät kaupunkiympäristön viihtyvyyttä (Tyrväinen ym. 2005). Näitä kaupunkimetsistä, -puistoista ja -puista koituvia hyötyjä kutsutaan ekosysteemipalveluiksi, mutta kaupunkipuilla on myös negatiivisia vaikutuksia, niin kutsuttuja haittapalveluja (Lyytimäki ym. 2008). Vanhat, huonokuntoiset tai myrskyssä kaatuvat puut voivat aiheuttaa asukkaille vaaraa tai vahingoittaa rakennuksia (Lyytimäki ja Sipilä 2009). Puiden siitepöly tuottaa joillekin terveysongelmia ja tiheät metsäalueet tai varjoiset puistot voivat luoda turvattomuuden tunnetta (Gómez-Baggethun ym. 2013). Hoitamattomat kaupunkimetsät ja -puistot voidaan kokea myös maisema-arvoja alentaviksi (Lyytimäki ym. 2008). Kaupunkipuiden istutukset, hoito ja ylläpitotoimet tuottavat paljon kustannuksia kaupungeille, sillä puistoissa ja kadun varsilla olevat puut vaativat intensiivistä hoitoa ja niiden kuntoa on tarkkailtava jatkuvasti (Tanhuanpää 2016).

Kaupunkipuiden tuottamien hyötyjen maksimointi ja toisaalta haittojen ja kustannusten minimointi edellyttää yksityiskohtaista tiedonkeruuta kaupunkialueen puustosta (Zhang ym. 2015). Kaupunkipuiden kartoituksella saadaan tärkeää tietoa puiden kunnosta, hoitotarpeesta ja muutoksista puustossa. Nämä tiedot auttavat kustannusten arvioimisessa ja resurssien kohdentamisessa eniten hoitoa tarvitseviin puihin (Tanhuanpää 2016). Monilla kaupungeilla on kartoituksen avulla tuotettu puurekisteri, joka sisältää tarkat tiedot yksittäisistä puista (Holopainen ym. 2013a). Uudet kaukokartoitusmenetelmät ja niiden nopea kehitys ovat mahdollistaneet puurekisterin tiedon keruun ja automatisoidun päivittämisen (Saarinen ym. 2014). Kaupunkipuiden kaukokartoitusmenetelmien kehitykseen on viime vuosina panostettu paljon ja esimerkiksi korkearesoluutioiset

ilmakuvamenetelmät ovat tähän asti olleet paljon käytössä (Liu ym. 2013). Optisia kuvia käyttävillä menetelmillä ei kuitenkaan saada tarkkaa kolmiulotteista tietoa (3D, three-dimensional) puustosta ja tästä johtuen kiinnostus laserkeilausmenetelmiin, joilla on mahdollista tuottaa tarkkaa 3D-informaatiota tutkittavasta kohteesta, on nopeassa kasvussa (Liu ym. 2013).

1.2 Kaupunkipuun määritelmä

Kaupunkipuun ja -metsän määritelmä on laaja-alainen ja katsontakannasta riippuvainen. Kaupunkimetsiin voidaan luokitella esimerkiksi vain luonnonkaltaiset metsäalueet, jotka sijaitsevat kaupunkien sisällä tai läheisyydessä, jolloin mm. rakennetut puistot jäävät määritelmän ulkopuolelle (Tyrväinen 2001). Laveampi määritelmä pitää sisältää kaikki kaupunkipuut tienvarsipuista yksittäisiin puisto- ja pihapuihin (Nowak ym 2001). Kaupunkipuiden luokittelu perustuu tyypillisesti puiden kasvupaikkaan, tiheyteen, laijijakaumaan ja puiden ylläpidon tärkeyteen. Yhden luokitteluperusteen esitti Tanhuanpää (2016), jossa kaupunkipuut luokitellaan neljään eri ryhmään. Teiden varsipuut, pihapuut, puistopuut ja virkistyskäyttöön tarkoitetut metsäalueet.

1.3 Kaupunkipuiden seuranta ja kartoitus

Kaupunkipuista kerätään tietoa strategisia pitkän ajan hoitosuunnitelmia ja operatiivisia vuosittaisia hoito- ja ylläpitotoimenpiteitä varten (Gustavsson ym. 2005). Kerätty tieto auttaa myös tunnistamaan minkä tyyppisiä ja kuinka paljon ekosysteemipalveluja kaupunkimetsät ja -puut pitävät sisällään (Bolund and Hunhammar 1999). Monet kunnat ja kaupungit ylläpitävät digitaalista puurekisteriä ja käytettävyyden kannalta puurekisterin tulisi sisältää vähintään tiedot puiden sijainnista, pituudesta ja läpimitasta (Holopainen ym. 2013a). Puurekisterin hyödyllisyys riippuu puukohtaisen tiedon ajantasaisuudesta, joten rekisteriä tulisi ylläpitää ja päivittää säännöllisesti (Tanhuanpää 2016). Kaukokartoitusmenetelmien ja -teknologian nopea kehitys on tarjonnut keinon tarkkaan puukohtaiseen tiedon keruuseen ja puurekisterin automatisoituun päivittämisen ilman maastomittauksia, jolloin kustannuksia, aikaa ja työmäärää on mahdollista säästää (Nielsen ym. 2014).

Kaukokartoituksen hyödyntäminen metsien inventoinnissa ja puiden kartoittamisessa alkoi jo 1900-luvun alkupuolella ilmakuvauksen myötä (Campbell ja Wynne 2011).

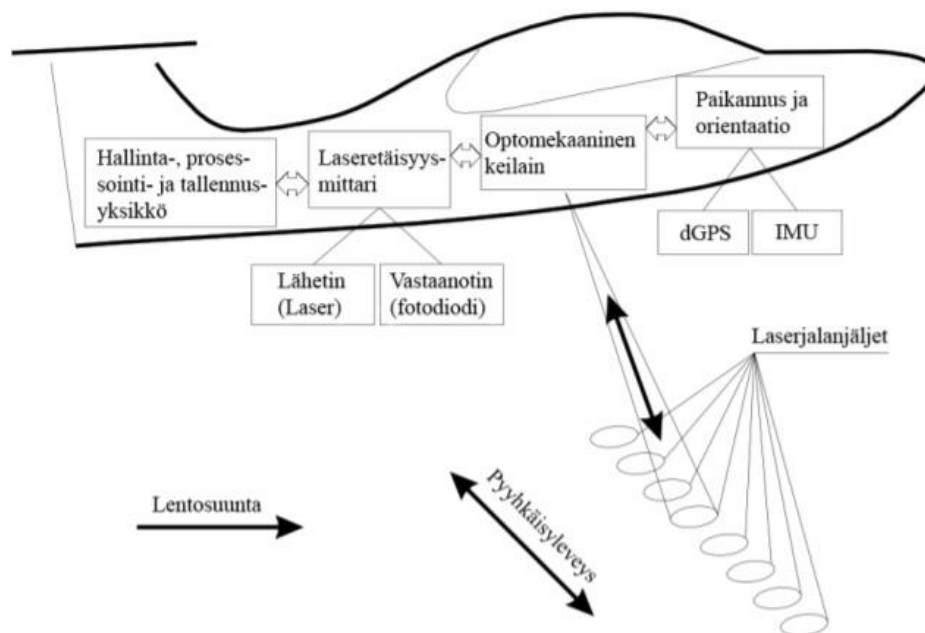
Menetelmien kirjo on sittemmin kasvanut korkean resoluution ilma- ja satelliittikuvista laserkeilaukseen. Näitä menetelmiä on hyödynnetty metsien inventoinnissa jo vuosikymmeniä ja ne ovat tarjonneet tehokkaan ja pitkälti automatisoidun menetelmän laajojen metsäalueiden kartoitukseen (Nielsen ym. 2014). Kaupunkipuista tarvitaan kuitenkin yksityiskohtaista puutason tietoa, jota on mahdollista saada nykyaikaisilla laserkeilaimilla ja fotogrammetrisillä menetelmillä (Nielsen ym. 2014). Laserkeilauksella on kuitenkin monia etuja fotogrammetriaan verrattuna. Laserkeilaus on kaukokartoitusmenetelmä, jossa hyödynnetään keilaimen itse tuottamaa energiaa ja näin ollen mittauksia on mahdollista suorittaa myös yöaikaan tai pilvisellä säällä (Holopainen ym. 2013b). Laserkeilaus mahdollistaa myös tiedon saannin maan pinnasta, puiden rakenteesta ja puiden alapuolisista kohteista, sillä laserpulssi läpäisee ylimmän latvuserroksen latvustossa olevien aukkojen kautta (Yao ym. 2013). Laserkeilainten pulssitiheyden kasvu on mahdollistanut tiheiden 3D-pistepilvien keräämisen, jolloin yksittäisistä puista voidaan laskea tunnuksia ja tämä kehitys onkin saanut aikaan kasvavan kiinnostuksen kaupunkiympäristön 3D-mallinnukseen (Secord ja Zankor, 2007).

1.4 Laserkeilaus

Laserkeilaus on kaukokartoitustekniikka, jolla saadaan 3D-tietoa tutkittavasta kohteesta, kuten maanpinnanmuodosta, kasvillisuudesta tai kaupunkialueiden infrastruktuurista (Hyypä ja Inkinen 1999). Laserkeilaimen toiminta perustuu keilaimen lähettämään laserpulssiin, joka kohteeseen osuttuaan siroaa ja osa pulssista heijastuu takaisin keilaimen sensoriin (Naesset 1997). Keilaimen ja kohteen välinen etäisyys mitataan laserpulssin kulkuajan perusteella (Vosselman ja Maas 2010). Laserkeilausmenetelmiä, joita käytetään metsän ja puutason kartoitukseen, on kolmen tyyppisiä. Lentolaserkeilaus (ALS, airborne laser scanning) mittaa kohdetta ilmasta. Maastolaserkeilaus (TLS, terrestrial laser scanning) on maanpinnalta kiinteältä jalustalta mittaava laserkeilausmenetelmä ja liikkuva maastolaserkeilaus (MLS, mobile laser scanning) on mittaussuunnitelma, jossa laserkeilain on asetettu esimerkiksi autoon tai mönkijään (Holopainen ym. 2013b). Seuraavassa kappaleessa käydään läpi pääperiaatteet lentolaserkeilauksesta, joka on ollut menetelmänä tässä tutkimuksessa käytetyn laserkeilausaineiston hankinnassa.

1.4.1 Lentolaserkeilaus

Lentolaserkeilaus (ALS) mittaa kohdetta yläpuolelta, jolloin keilain on tyypillisesti asetettu esim. lentokoneeseen tai helikopteriin ja nykyisin myös miehittämättömiin ilma-aluksiin, kuten droneihin (Jaakkola ym. 2010). Laserkeilain lähettää laserpulsseja alaspäin kohtisuoraan lentosuuntaan nähden ja kohteen välinen etäisyys mitataan laserpulssin kulkuajan perusteella (Holopainen ym. 2013b). Laserkeilauslaitteisto koostuu laserpulssin lähetinyksiköstä ja pulssista heijastuneiden kaikujen vastaanottimesta, keilainosasta ja tiedontallennus ja prosessointiyksiköstä (Wehr ja Lohr 1999). Laitteistoon on yhdistetty myös sijaintia, nopeutta ja suuntaa mittaavat DGPS (Differential Global Positioning Systems) järjestelmä, joka mittaa sijaintia satelliittien ja maassa olevan kiinteän mittausaseman avulla ja IMU (Inertia Measurement Unit) järjestelmä, joka mittaa sensorin asentoa ja paikkaa (Naessset 1997). Lisäksi nämä eri yksiköt ja järjestelmät vaativat keskinäisen synkronoinnin, jotta mitatut tiedot on mahdollista yhdistää toisiinsa (Wehr ja Lohr 1999). Kuvassa 1 on havainnollistettu lentolaserkeilauslaitteisto.



Kuva 1. Lentolaserkeilauslaitteisto (Holopainen ym. 2013b, kuvan ©Ville Kankare).

Lentolaserkeilauksen tuottamaan dataan voidaan vaikuttaa eri keilausparametreja muuttamalla. Näitä parametreja ovat mm. Lentonopeus ja -korkeus, avauskulma,

pulssitaajuus, keilauskulma ja tallennettavien kaikujen määrä (Holopainen ym. 2013b). Kun laserkeilaimen tarkka sijainti ja asento ovat tiedossa, pystytään mitattu etäisyys muuttamaan korkeudeksi ja kohteesta heijastuneille pisteille voidaan laskea x-, y- ja z-koordinaatti (Vosselman ja Maas 2010). Sijainnin sisältävät korkeuspisteet muodostavat pistepilviaineiston, jota prosessoimalla voidaan laskea puustotietoja yksittäisen puun tai metsikön tasolla (Hyypä ja Inkinen 1999).

Laserpulssin osuma maanpintaan tai puustoon voi tuottaa yhden tai useamman kaiun (Campbell ja Wynne 2011). Pulssin osuessa tiheään lehvästään tai puustossa olevan aukon läpi suoraan maahan, tuottaa se usein vain yhden paluukaiun, mutta pulssi voi myös osua moneen eri kohtaan latvusta ja lopulta maan pintaa, jolloin se tuottaa useamman paluukaiun (Holopainen ym. 2013b). Maanpinnasta heijastuneista paluukaiuista on mahdollista määrittää maanpinnan taso ja puustosta heijastuneista paluukaiuista saadaan tärkeää tietoa puuston rakenteesta (Campbell ja Wynne 2011). Paluukaiun tallentavia tekniikoita on kahdenlaisia. Perinteisesti paluukaiusta tallennetaan sen intensiteetin huippuarvot, jolloin siitä rekisteröityy yksi tai useampi erillinen piste (Wher ja Lohr 1999). Koko aaltomuodon tallentava (Full-waveform) tekniikka tallentaa paluukaiun kokonaan (Wher ja Lohr 1999). Aaltomuototekniikalla saadaan tietoa puun rakenteesta koko puun pituudelta maanpintaan, mutta suuren datamäärän vuoksi sitä on hidasta prosessoida ja tallentaa. (Lim ym. 2003)

Puustotietojen tuottaminen lentolaserkeilausaineistosta voidaan jakaa kahteen päämenetelmään. Aluepohjaiseen menetelmä (Naesset 1997) ja yksinpuintulkintaan (Hyypä ja Inkinen 1999). Aluepohjaisessa menetelmässä puustotunnuksia ennustetaan mallintamalla tilastollinen riippuvuus maastossa mitattujen tunnusten ja vastaavalta alueelta laskettujen ALS-piirteiden välillä (Naesset 1997). Yksinpuintulkinnassa puustotiedot mitataan joko suoraan 3D-pistepilvestä tai luomalla tilastollinen malli ALS-piirteiden ja maastomittauksien välille (Yu ym. 2011).

Aluepohjaisissa menetelmissä hyödynnetään harvapulssista laserkeilausta ja se soveltuu laajojen metsäalueiden inventointiin, mutta vaatii tarkasti mitattuja maastokoealoja (Holopainen ym. 2013b). Aluepohjaiset menetelmät soveltuvat metsikkötason tunnusten keskiarvojen mittaamiseen, joista tärkeimpänä puiden keskipituus (Naesset 1997). Laserkeilausteknologian kehitys ja pulssitiheyden nopea kasvu on mahdollistanut

yksittäisten puiden havainnoinnin ja puutunnusten, kuten pituuden ja latvusleveyden mittaamisen yksittäisille puille suoraan ALS-pisteaineistosta (Persson ym. 2002). Pituuden ja latvusleveyden avulla voidaan ennustaa esimerkiksi puiden läpimitta ja tilavuus (Persson ym. 2002).

Hyypä ja Inkinen (1999) esittivät yksinpuintulkintamenetelmän, jossa yksittäisten puiden sijainti voidaan määrittää segmentoimalla latvukset ja etsimällä paikallisia maksimiarvoja. Yksinpuintulkinnan merkittävämpiä etuja on, ettei maastomittauksia välttämättä tarvita ollenkaan. Kaupunkipuiden lajijakauman, iän ja alueellisen rakenteen vaihtelevuus on suurta verrattuna tavallisiin metsäalueisiin ja näin ollen kaupunkipuista tarvitaan yksityiskohtaista tietoa (Zhang ym. 2015). Yksinpuintulkintamenetelmä tarjoaakin potentiaalisen tavan kaupunkipuiden kartoitukseen ja seurantaan Seuraavassa kappaleessa käydään yksityiskohtaisemmin läpi yksinpuintulkintamenetelmää.

1.4.2 ALS-aineiston prosessointi yksinpuintulkinnassa

ALS-aineiston prosessointi yksinpuintulkinnassa voidaan jakaa kolmeen vaiheeseen. Aluksi yksittäiset puut havaitaan ja paikannetaan. Tämä tapahtuu useimmiten etsimällä paikallisia maksimiarvoja latvuston pintamallista (CHM, canopy height model) (Holopainen ym. 2013b). Seuraavaksi puiden yksittäiset latvukset rajataan esimerkiksi valuma-alue segmentoinnilla (Hyypä ja Inkinen 1999) tai alue-kasvatus (region growing) menetelmään perustuen (Lu ym. 2014). Lopuksi yksittäisille puille voidaan määrittää puutunnukset, kuten pituus ja latvuksen läpimitta, joista voidaan johtaa muita tunnuksia, kuten rungon läpimitta ja runkotilavuus (Persson ym. 2002). Yksinpuintulkintamenetelmät voidaan jakaa karkeasti kahteen luokkaan: Pintamalleihin perustuviin menetelmiin ja 3D-pistepilvimenetelmiin. Viime vuosiin asti pintamallimenetelmät ovat olleet päämenetelmänä yksinpuintulkinnassa (Lu ym. 2014).

1.4.3 Pintamallimenetelmät

pintamallimenetelmien käyttö perustuu pistemäisistä korkeustiedoista muodostettujen pintojen käyttöön, jotka ovat tyypillisesti rasterimuodossa. Hyypä ja Inkinen (1999) esittivät menetelmän, jossa laserkeilauksen tuottama x-, y- ja z-koordinaatit sisältävä pistepilvi muunnetaan rasterimuotoon ja luodaan digitaalinen pintamalli, johon sisältyy

maasta, kasvillisuudesta ja muista mahdollisista maastossa olevista objekteista heijastuneita pisteitä. Aineistoa prosessoimalla ja luokittelemalla erotellaan kasvillisuudesta ja maanpinnasta heijastuneet pisteet erilleen ja muodostetaan niistä maan pinnan maastomalli (DTM, Digital Terrain Model), sekä latvuston pintaa kuvaava pintamalli (DCM, Digital Canopy Model). Näiden pintamallien erotuksena saadaan puiden pituutta kuvaava latvuston pintamalli (CHM, Canopy Height Model). Latvuksen korkeusmallia suodatetaan, jotta mallin korkeusvaihtelut tasoittuvat ja segmentointi tuottaisi mahdollisimman realistisen määrän latvussegmenttejä. Valuma-alue segmentoinnilla latvukset rajautuvat omiksi segmenteiksi, joiden huippukohdat määrittävät puiden sijainnit.

Pintamallimenetelmien ongelmakohtana voidaan pitää alemmissa latvuserroksissa olevien puiden heikkoa havaitsemista, sillä ne jäävät usein näkymättömiin ylemmästä latvuserroksesta muodostuvan CHM:n alle (Yao ja Wei 2013)

1.4.4 3D-Menetelmät

Laserkeilainten pulssintoistotaajuuden nopea kehitys ja useiden kaikujen tai jopa koko aaltomuodon tallennusmahdollisuus sekä muiden ominaisuuksien kehitys on mahdollistanut tarkan ja tiheän pistepilviaineiston saamisen ja 3D-mallien tuottamisen (Holopainen ym. 2013b). 3D-pohjaiset yksinpuinmenetelmien tutkimus ja kehitys onkin viime aikoina lisääntynyt (Liu ym. 2013).

3D-pistepilvimenetelmissä hyödynnetään koko pistepilviaineistoa, jolloin saadaan tietoa latvuksen alemmista osista, puun rungosta ja korkeimman latvuserroksen alle jäävistä pienemmistä puista (Holopainen ym. 2013b). Osa laserpulssin valosta pääsee ylimmän latvuspinnan läpi alempiin latvuserroksiin ja aina maahan asti ja näin ollen on mahdollista rajata yksittäisten puiden latvuksia kolmiulotteisesti laserkeilausaineistosta (Lindberg ja Holmberg 2017). Erilaisia 3D-menetelmiä on suuri määrä verrattuna pintamallimenetelmiin. ALS aineiston esiprosessointivaiheet ovat kuitenkin hyvin samankaltaiset kuin pintamallimenetelmissä.

1.4.5 Kaupunkipuiden yksinpuintulkinta

Yksityiskohtaisen tiedon kerääminen kaupunkialueen puustosta kaukokartoitusmenetelmillä on ollut nopeassa kasvussa 2000-luvulta lähtien ja viime vuosina erityisesti laserkeilausmenetelmien mahdollisuuksia kaupunkipuiden yksinpuintulkinnassa on tutkittu laajasti (Ciesielski ja Sterenczak 2019). Yleisimpiä kaukokartoitusmenetelmiä kaupunkipuiden yksinpuintulkintatutkimuksissa viime vuosina ovat olleet korkean resoluution ilma- ja satelliittikuvaus (esim. Ardila ym. 2012, Morgenroth ja Gomez 2014), lentolaserkeilaus (esim. Tanhuanpää ym. 2014, Rahman ja Rashed 2015, Plowright ym. 2016) sekä maastolaserkeilaus ja liikkuva maastolaserkeilaus (Rutzinger ym. 2011, Wu ym. 2013). Näiden lisäksi tutkimuksissa on käytetty edellä mainittujen menetelmien yhdistelmiä (esim. Holopainen ym. 2013, Alonzo ym. 2014, Lee ym. 2016).

Ciesielski ja Sterenczak (2019) vertailivat erilaisia kaupunkipuiden kartoitustutkimuksessa käytettyjä kaukokartoitusmenetelmiä ja niiden tarkkuutta yksityiskohtaisten puutunnusten, kuten sijainnin, pituuden, läpimitan ja latvusleveyden määrittämisessä. Tuloksista käy ilmi, että eri menetelmiä ja niiden yhdistelmiä on hyvin laaja kirjo ja tuloksissa on ilmennyt suurta vaihtelua riippuen käytetystä kaukokartoitusmenetelmästä ja puiden kartoitus- ja mallinnusalgoritmista riippuen.

Kaupunkipuiden yksinpuintulkinta nostaa esiin monenlaisia haasteita verrattuna perinteisen talousmetsän yksinpuintulkintaan. Kaupunkiympäristö on hyvin vaihtelevaa ja koostuu rakennusten, teiden, puiden ja muiden rakennelmien mosaiikista, mikä tekee maaston ja kasvillisuuden erottelun laserkeilausaineiston prosessoinnissa haastavaa (Liu ym. 2013). Puuston alueellinen moninaisuus ja lajikirjo on kaupunkialueilla metsäalueisiin verrattuna yleensä huomattavasti suurempi ja kaupunkipuiden koossa, pituuksissa ja latvusten leveyksissä on suurta vaihtelua metsäpuihin verrattuna (Zhang ym. 2015).

Yksi merkittävä ongelma kaupunkipuiden kartoituksessa ja puiden havaitsemisessa kaukokartoitusaineistosta on suuret leveälatvuksiset puistopuut ja erityisesti lehtipuut, joiden latvus on usein jakautunut useaan suureen oksahaaraan ja näin ollen puulla saattaa olla useita erillisiä latvoja (Tanhuanpää ym. 2019). Leveälatvuksiset puut aiheuttavat ylisegmentoitumista, joka johtaa puiden määrän yliarvioon ja toisaalta suurien ja

leveälatvuksisten puiden alle jää pienempiä puita piiloon, joita ei havaita (Zhang ym. 2015). Suurten latvusten alle jäävien pienien puiden havaitsemiseen ja suurien levälatvuksisten puiden ylisegmentoitumiseen on pyritty löytämään ratkaisua erilaisilla yksinpuintulkintamenetelmillä ja puidentunnistusalgoritmeilla.

Holopainen ym. (2013) tutkivat eri laserkeilausmenetelmien (ALS, TLS ja MLS) kaupunkipuiden kartoitustarkkuutta hyödyntäen 3D-pistepilvimenetelmiä. Tutkimusalue koostui hoidetusta puistoalueesta ja luonnontilaisesta metsäalueesta. Tutkimuksessa puiden havaitsemistarkkuutta tutkittiin automaattisia ja manuaalisia menetelmiä hyödyntäen. Puiden havaitsemistarkkuus vaihteli menetelmien välillä 65-80 %:n välillä. Parhaiten puiden havaitseminen onnistui manuaalisella MLS-menetelmällä (79,22 %) ja automaattisella TLS-menetelmällä (73,29 %).

Matschi ym. (2018) tutkivat ALS-aineiston yksinpuintulkinnan mahdollisuuksia suurien yli 15 m pitkien puistopuiden kartoittamisessa Vancouverin kaupungissa. Tutkimuksen latvuskartan luonnissa hyödynnettiin latvuston pintamallista valuma-aluesegmentointiin perustuvaa latvussegmentointimenetelmää. ALS-aineistoa prosessoidessa ja pintamallin luonnissa otettiin huomioon, että kiinnostuksen kohteena on juuri suuret puut. Tutkimuksessa selvitettiin mm. menetelmän puiden havaitsemistarkkuus ja kyky tunnistaa onko havaittu puu lehti- vai havupuu. Tutkimuksessa puiden havaitsemistarkkuudeksi saatiin 76,6 % ja menetelmä pystyi erottelemaan lehtipuut havupuista 86,9 % tarkkuudella.

Saarin ym. (2014) tutkivat mahdollisuutta kaupunkipuurekisterin puustotietojen päivittämistä monilähteisellä yksinpuintulkintamenetelmällä. Tutkimuksessa käytettiin TLS- ja ALS aineistoa. Tutkimuksessa luotiin puukartta TLS-aineistolla, josta saatiin puiden tarkat runkojen sijainnit. ALS-aineistosta puiden latvukset rajattiin valuma-aluesegmentointimenetelmällä ja luodut latvussegmentit yhdistettiin referenssipuihin TLS-aineistosta määritettyjen referenssipuiden sijainnin perusteella. Mikäli latvussegmentin sisään osui useampi kuin yksi referenssipuu, jaettiin latvussegmentti tasaisesti siihen osuvien referenssipuiden kesken. Puille mallinnettiin läpimitta ALS-aineiston pistepilvestä irrotettujen piirteiden avulla. RF- ja kNN-menetelmillä. Puiden läpimittaennusteiden suhteellinen RMSE vaihteli 25,0–33,8 %:n välillä metsäisellä alueella ja 18,8–20,1 %:n välillä puistoalueella. Tutkimus osoitti, että menetelmällä

pystytään päivittämään puurekisterin puutunnuksia kohtalaisen tarkasti.

Yksi uusimmista ALS-aineiston yksinpuintulkintaan perustuvista kaupunkipuututkimuksista on Tanhuanpään ym. (2019) Helsingin puistopuiden kartoitusta selvittävä tutkimus. Siinä kokeiltiin yhdeksää eri latvuston pintamallin latvussegmentointimenetelmää kolmessa puustorakenteeltaan erilaisella puistoalueella. Tutkimuksen paras menetelmä tuotti koko alueella lievän aliarvion puiden määrästä. Ositekohtaisesta arvioinnista kävi ilmi, että harvapuustoisella alueilla kaikki menetelmät tuottivat yliarvion puiden määrään. Tutkimustuloksista kävi myös ilmi, että yksiselitteisesti parasta latvussegmentointi menetelmää koko tutkimusalueelle ei löytynyt ja tulokset vaihtelivat huomattavan paljon menetelmästä ja alueen puustosta riippuen. Tutkimuksen perusteella yksi suurin haaste puistopuiden kartoituksessa oli suuret lehtipuut, jotka jakautuvat helposti useaan eri latvussegmenttiin, tuottaen näin yliarvion puiden määrästä. Suurien ja leveälatvaisten puiden alle jäi toisaalta myös pienempiä puita piiloon, joita ei havaittu ja se taas aiheutti aliarviota puumäärään.

1.5 Tutkimuksen tavoitteet ja tutkimusongelma

Tutkimuksen päätavoitteena oli selvittää, onko puistopuiden kartoitusmenetelmän tarkkuutta mahdollista parantaa puoliautomaattisesti tuotetulla latvuskartalla. Erityisesti tutkimuksessa keskityttiin löytämään ratkaisua suurien leveälatvuksisten puiden ylisegmentoitumiseen, joka on noussut esiin monissa aikaisemmissa yksinpuintulkintamenetelmiä hyödyntävissä kaupunkipuiden kartoitustutkimuksissa (esim. Höfle ym. 2012, Holopainen ym. 2013, Zhang ym. 2015, Tanhuanpää ym. 2019).

Tutkimuksessa luotiin ALS-aineiston avulla yhdeksälle Helsingin sairaala-alueelle yksityiskohtainen latvuskartta, joka sisälsi puukohtaiset sijainti- ja läpimittatunnukset. Latvuskartat tuotettiin segmentoimalla puiden latvukset ALS-aineistosta luodusta latvuston pintamallista. Aluksi latvussegmentit tuotettiin automaattisella menetelmällä, jonka jälkeen latvussegmentointia muokattiin visuaalisesti ortoilmakuvia ja latvustonpintamallia hyväksi käyttäen. Muokkauksen tuloksena saatiin uusi puoliautomaattisella menetelmällä tuotettu latvuskartta.

Automaattisen ja puoliautomaattisen latvussegmentointimenetelmän paremmuutta

arvioitiin määrittämällä ALS-aineistosta tuotettujen puiden havaitsemistarkkuus ja puiden läpimitan mallinnustarkkuus menetelmäkohtaisesti. ALS-aineistosta automaattisella ja puoliautomaattisella menetelmällä tuotettuja puumääriä ja ennustettuja läpimittoja verrattiin maastossa mitattujen puiden määriin ja läpimittoihin. Tutkimuksessa oli myös tavoitteena selvittää miten referenssipuiden läpimitta ja puulaji vaikuttavat automaattisen ja puoliautomaattisen menetelmän puiden havaitsemistarkkuuteen ja läpimitan mallinnustarkkuuteen.

Tutkimuksen tutkimuskysymyksiä olivat:

1. Parantaako puoliautomaattisesti tuotettu latvuskartta puistopuiden kartoitustarkkuutta?
2. Millainen vaikutus puiden läpimitalla on automaattisen ja puoliautomaattisen menetelmän puiden kartoitustarkkuuteen?
3. Millainen vaikutus puulajilla on automaattisen ja puoliautomaattisen menetelmän puiden kartoitustarkkuuteen?

2 AINEISTO JA MENETELMÄT

2.1 Tutkimusalue

Tutkimusalue koostui yhdeksästä Helsingin sairaala-alueesta, joita olivat: Auroran, Herttoniemen, Kivelän, Koskelan, Laakson, Malmin, Marian, Myllypuron ja Suursuon sairaala-alueet. Tutkimusalueiden pinta-ala vaihteli 1-10 ha välillä ja tutkimusalueiden yhteenlaskettu pinta-ala oli 47,2 ha. Pääosin tutkimusalueet koostuivat rakennetusta kaupunkiympäristöstä, mutta hoidettujen puistoalueiden lisäksi alueilta löytyi myös tiheäpuustoisia hoitamattomia metsäalueita.

Tutkimusalueiden puusto koostui hoidetuista yksittäisistä katu- ja puistopuista, viheralueilla kasvavista puuryhmistä ja lähes luonnontilaisista metsäalueiden puista. Auroran, Kivelän, Koskelan ja Laakson tutkimusalueiden puiden kasvupaikat olivat hyvin vaihtelevia, koostuen yksittäisten puistopuiden lisäksi tiheäpuustoisista metsäalueista. Muilla tutkimusalueilla puusto koostui lähinnä hoidetuista yksittäisistä

katu- ja puistopuista tai puistopuuryhmistä. Metsäisten alueiden vähän hoidettu ja osin luonnontilainen puusto koostui suurilta osin yleisistä metsäpuulajeistamme, kuten kuusista, männyistä, koivuista ja haavoista. Puistoisilla alueilla puiden lajikirjo oli huomattavasti monipuolisempi ja niissä kasvoi paljon vanhoja lehti- ja havupuita. Puiden kokojakauma ylettyi pienistä taimista aina hyvin kookkaisiin vanhoihin puistopuihin. Hoidetuilla puistoisilla alueilla oli lähinnä istutettuja puistopuita ja metsäisillä alueilla luontaisesti syntyneitä metsäpuita. Kokonaisuudessaan alueiden puusto oli hyvin monimuotoista. Tutkimusalueina olleet sairaala-alueet kartalla kuvassa 2.



Kuva 2. Tutkimusalueet rajattuna mustalla viivalla. Helsingin yleiskartta (2020). Haettu osoitteesta <https://hri.fi/fi/> CC-BY. <https://creativecommons.org/licenses/by/4.0/>

2.2 Maastoaineisto

Maastossa mitattiin tutkimusalueiden kaikki läpimitaltaan yli 5 cm puut. Puille määritettiin sijainti, läpimitta ja puulaji. Sijaintiedot määritettiin Trimble TSC3 ja Trimble TSC7 tarkkuus GPS-paikantimilla. Läpimitta määritettiin mittasaksilla rinnankorkeusläpimittoina 1,3 m korkeudelta puun juurelta. 1,3 m alapuolelta haaroittuneista puista mitattiin jokaisen haaran läpimitta erikseen. Maastoaineistosta luotiin puukartta, johon tallennettiin edellä mainitut tiedot jokaisesta puusta. Puukartta toimitettiin Helsingin kaupungille ja sitä käytettiin tutkielman referenssiaineistona työn

tuloksia tarkasteltaessa. Referenssipuita oli yhteensä 4365 ja puulajeja 37 (Taulukko 1). Puiden minimi-, keski- ja maksimiläpimitta olivat 5 cm, 24 cm ja 125 cm.

Taulukko 1. Maastossa mitatut puulajit ja määrät.

Puulaji	Määrä	Puulaji	Määrä
Rauduskoivu	802	Saarni	19
Vaahtera	671	Ruotsin pihlaja	18
Haapa	662	Tervaleppä	16
Mänty	629	Salava	15
Pihlaja	383	Kirsikkapuu	13
Vuorijalava	286	Sembramänty	12
Lehmus	186	Poppeli	12
Tuomi	113	Hevoskastanja	11
Omenapuu	73	Marjakuusi	10
Kuusi	59	Terijoen salava	10
Tammi	57	Selja	9
Raita	52	Lehtikuusi	8
Tuija	51	Oraapihlaja	3
Pihta	37	Pyökki	3
Hieskoivu	33	Hikkori	3
Syreeni	33	Valkosalava	2
Jalopähkinä	25	Vuorimänty	2
Harmaaleppä	24	Kataja	1
Tunnistamaton	22		
Yhteensä	4365		


2.3 Laserkeilausaineisto

Laserkeilausaineistona tutkielmassa käytettiin Helsingin kaupungin kesällä vuonna 2017 keräämää ALS-aineistoa. Aineisto oli kerätty monikanavaisella Optech Titan -keilaimella ja sen pistetiheys oli noin 50 pistettä/m². Laserpulslien paluukaiuista muodostuneesta pistepilviaineistosta oli muodostettu Terrascan -ohjelmalla rasterimuotoiset maaston pintamalli (digital terrain model, DTM) ja maanpinnan yläpuolisia kohteita kuvaava pintamalli (digital surface model, DSM). Maaston pintamallirasterin solukoko oli 1 m ja maan pinnan yläpuolisia kohteita kuvaavan pintamallirasterin solukoko oli 0,5 m. Näiden pintamallien erotuksena oli tuotettu normalisoitu latvuston pintamalli (canopy height model, CHM). Tätä rasterimuotoista latvuston pintamallia, jonka solukoko oli 0,5 m, käytettiin tutkimuksen latvuskarttana.

2.4 Latvuston pintamallin prosessointi

2.4.1 Latvuston pintamallin suodatus


Prosessoinnin ensimmäisessä vaiheessa tutkimusalueen puustolle muodostettua rasterimuotoista latvuston pintamallia suodatettiin (Kuva 3). Latvuston pintamallia suodatettiin Kaartisen ym. (2012) tutkimusartikkelissa esittelemällä suodatusmenetelmällä. Menetelmässä jokaista latvuston pintamallin rasterisolua suodatetaan 3x3 kuvaikkunalla. Kuvaikkunan keskimääräinen rasterisolu saa painoarvoksi 42,9 % ja muut ympärillä olevat solut saa 7,1 % painoarvon. Suodatettavan solun korkeusarvoa säädetään siis ympärillä olevien solujen perusteella edellä mainituilla painotuksilla. Suodatuksen tarkoituksena on tasoittaa pintamallin korkeusvaihtelua ja yksinkertaistaa sitä niin, että yksittäinen pintamallin huippu kuvaa yksittäisen puun latvusta. Suodatus on olennainen osa latvusten segmentointia ja vaikuttaa suurelta osin puiden määrään ja yksittäisten latvussegmenttien kokoon. Liian lievä suodatus johtaa helposti ylisegmentointiin, jolloin latvussegmenttejä syntyy esimerkiksi puiden oksahaaroista. Tämä johtaa puiden määrän yliarvioon. Liian voimakas suodatus voi taas tasoittaa latvuston pintamallia liikaa, jolloin varsinkin pienet lähekkäin kasvavat puut sulautuvat helposti samaan segmenttiin ja puiden määrä aliarvioidaan. Tyypillisesti vanha puusto vaatii voimakkaamman suodatuksen, kun taas nuoren puuston liian voimakas suodatus tasoittaa matalan latvuston vaihtelua liikaa (Tanhuanpää ym. 2019).



Kuva 3. Suodattamaton ja suodatettu latvuston pintamalli.

2.3.2 Automaattinen latvussegmentointi

Suodatetusta latvuston pintamallista yksittäiset puiden latvukset rajattiin Hyypän ja Inkisen (1999) tutkimuksessa esitetyn valuma-aluesegmentointitavan avulla. Menetelmä etsii automaattisesti latvuston pintamallista paikallisia huippuja, jotka määrittävät puille latvapisteen. Nämä latvapisteet antavat puille samalla myös sijainnin. Paikallisten maksimiarvojen löydyttyä jokaisen latvapisteen ympärille muodostuu latvussegmentti. Latvussegmenttien rajat piirtyvät latvuston pintamallin muodoista erottuvien yksittäisten latvusten ulkorajoille ja jokainen pintamallin huippu tuottaa aina yhden latvussegmentin (Kuva 4).



Kuva 4. Vasemmalla latvuston pintamalli latvapisteineen ja oikealla latvuston pintamalli, latvapisteet sekä niiden ympärille muodostuneet latvussegmentit.

Latvussegmentoinnissa käytettiin korkeuden kynnsarvoja. Rasterisolujen korkeusarvon alaraja oli 2,5 metriä, jolloin sitä alhaisemmat korkeusarvon sisältämät rasterisolut rajautuivat aineistosta pois ja yläraja oli 33 metriä, jolloin sitä korkeamman korkeusarvon sisältämät rasterisolut rajautuivat pois. Tällä toimenpiteellä pyrittiin siihen, että segmentointiaineistoon ei tulisi mukaan pensaita tai pieniä puita, jotka ovat alle 2,5 metriä pitkiä ja joiden läpimitta on näin ollen suurella todennäköisyydellä alle 5 cm. Rasterisolut, joiden korkeusarvo olisi ollut yli 33 metriä, olisivat olleet virheitä aineistossa, sillä tutkimusalueilla ei ollut yli 33 metrisiä puita. Latvussegmenttiaineistosta poistettiin tässä vaiheessa myös kaikki sellaiset latvussegmentit, jotka olivat selvästi muodostuneet muista kuin puiden latvuksista, kuten lampputolpista ja liikennemerkkeistä.

2.3.3 Puoliautomaattinen latvussegmentointi

Automaattisen latvussegmentoinnin jälkeen siirryttiin puoliautomaattiseen työvaiheeseen, jossa muokattiin virheellisiksi osoittautuneita automaattisen menetelmän tuottamia latvussegmenttejä. Tämän silmävaraisen muokkauksen tuloksena saatiin uusi puoliautomaattisesti tuotettu latvussegmentointi (Kuva 5).




Kuva 5. Automaattinen latvussegmentointi vasemmalla ja puoliautomaattinen latvussegmentointi oikealla.

Automaattisen latvussegmentoinnin tuloksia tarkasteltiin visuaalisesti ja vertailtiin neljään vuosilta 2015-2019 olevaan ortoilmakuvaan sekä alkuperäiseen suodattamattomaan latvuston pintamalliin. Puoliautomaattinen latvussegmentointiprosessi voidaan jakaa neljään työvaiheeseen:

1. Automaattisen menetelmän tuottamat latvussegmenttien rajat siirretään ilmakuvien päälle ja latvussegmenttejä käydään yksitellen läpi vertaamalla niitä ilmakuvilta ja latvuston pintamallista hahmottuviin puiden latvuksiin (Kuva 5).
2. Mikäli havaitaan, että puun latvus on rajautunut virheellisesti useaan eri latvussegmenttiin, segmenttien sisältämistä latvapisteistä jätetään vain yksi puun sijaintia parhaiten kuvaava latvapiste jäljelle ja muut poistetaan. Mikäli havaitaan, että jokin latvussegmentti sisältää selkeästi useamman eri puun latvuksen, erotellaan latvukset silmämääräisesti omiin segmentteihin ja uusille latvussegmenteille määritetään latvapiste.
3. Kaikille ylimääräisille latvussegmenteille, joista latvapiste on poistettu, määritetään lähin latvapisteen sisältävä latvussegmentti.

4. Kun kaikille ylimääräisille latvussegmenteille on löytynyt lähin latvapiste, liitetään samaan latvapisteeseen yhdistyneet latvussegmentit toisiinsa, jolloin kaikki samaan latvapisteeseen yhdistyneet segmentit muodostavat yhden koko latvusta kuvaavan latvussegmentin.

Latvussegmenttien muokkauksessa keskityttiin erityisesti monihaaraisiin ja leveälatvuksiin lehtipuihin, jotka tuottavat automaattisella segmentoinnilla usein virheellisesti yhden puun latvukselle monta erillistä latvussegmenttiä (Kuva 6). Kaikki tämän työn latvussegmentointiin liittyvät työvaiheet toteutettiin ArcMap -ohjelmalla.



Kuva 6. Useaan eri latvussegmenttiin jakautunut rauduskoivu. Automaattisella menetelmällä tuotettu latvussegmentointi vasemmalla ja puoliautomaattisella menetelmällä muokattu latvussegmentointi oikealla. Punaiset pisteet ovat ALS-aineistosta määritettyjen latvussegmenttien latvapisteitä ja sininen piste on maastossa mitattu puun todellinen sijaintipiste.

2.5 Automaattisen ja puoliautomaattisen menetelmän tarkkuuden arviointi

2.5.1 Puiden havaitsemistarkkuuden arviointi

Automaattisen ja puoliautomaattisen latvussegmentoinnin paremmuutta tutkittiin vertaamalla menetelmien puiden havaitsemistarkkuutta ja puiden läpimitan mallinnustarkkuutta. Puiden havaitsemistarkkuutta ALS-aineistosta voidaan tarkastella usealla eri periaatteella ja tarkastelunäkökulma valitaan vastaamaan tutkimuksen tavoitteita. Latvussegmenttien yhdistäminen referenssipuihin sisältää aina jossain määrin epävarmuutta.

Yksi tavoista arvioida puiden havaitsemistarkkuutta on verrata suoraan latvussegmenttien määrää referenssipuumäärään, jolloin latvussegmenttejä ei yhdistetä tiettyihin referenssipuihin. Tällöin ei kuitenkaan voida arvioida kuinka monta todellista puuta ja mitkä referenssipuista ovat tarkalleen ottaen havaittu. Mikäli puiden havaitsemistarkkuutta halutaan arvioida puutasolla, voidaan laserkeilausaineistosta havaituiksi puiksi laskea vain sellaiset latvussegmentit, jotka ovat yksiselitteisesti yhdistettävissä tiettyyn referenssipuuhun. Latvussegmenttien yhdistäminen tiettyyn referenssipuuhun sisältää kuitenkin paljon haasteita. Latvussegmentit saattavat yhdistyä väärään referenssipuuhun erityisesti sellaisilla alueilla, joissa puiden kokovaihtelu on suurta ja pienempiä puita jää suurempien puiden alle. Esimerkiksi tilanteessa, jossa suuren lehtipuun latvus on jakautunut moneksi eri segmentiksi ja kyseisen puun alla kasvaa pienempiä puita, voi jokin suuren puun oksahaarasta muodostunut latvussegmentti yhdistyä alla kasvavaan referenssipuuhun. Myös alueilla, joissa on tiheä puusto, tuottaa latvussegmentointi usein paljon virheellisiä latvussegmenttejä, jolloin latvussegmenttien yhdistyminen oikeisiin referenssipuihin on epävarmaa. ALS-aineiston latvussegmentit voidaan yleisesti jakaa puiden havaitsemisen suhteen neljään eri kategoriaan: Latvussegmentti on yhdistynyt oikeaan referenssi puuhun, väärään referenssipuuhun, useaan referenssipuuhun tai ei mihinkään referenssipuuhun.

Tässä tutkimuksessa puiden havaitsemistarkkuuden arviointi suoritettiin kahdella eri tavalla. Ensimmäiseksi verrattiin automaattisen ja puoliautomaattisen menetelmän tuottamaa latvussegmenttimäärää maastossa mitattuun todelliseen puumäärään olettaen, että jokainen latvussegmentti vastaa yhtä maastossa mitattua referenssipuuta. Toiseksi puiden havaitsemistarkkuutta arvioitiin määrittämällä automaattisen ja puoliautomaattisen menetelmän tuottamien komissiovirheiden määrä.

Komissiovirheeksi kutsutaan tilannetta, jossa menetelmä havaitsee ALS-aineistosta puun, jota ei ole olemassa. Komissiovirheitä ovat siis tässä tutkimuksessa sellaiset latvussegmentit, joiden alalta ei löydy yhtään referenssipuuta ja niitä voi syntyä esimerkiksi puiden oksahaaroista muodostuneista latvussegmenteistä. ALS-aineistosta tuotetusta latvuskartasta määritetään yleensä myös niin kutsutut omissiovirheet. Omissiovirheet ovat sellaisia referenssipuita, joita menetelmä ei havaitse ALS-aineistosta. Omissiovirheitä syntyy esimerkiksi pienistä puista, jotka jäävät suurempien puiden latvuksien alle tai tiheäpuustosilla alueilla, joissa samoihin latvussegmentteihin sulautuu

useamman puun latvus. Tässä tutkimuksessa keskityttiin vertailemaan pelkästään automaattisen ja puoliautomaattisen menetelmän tuottamia komissiovirheiden määriä, koska tutkimuksessa käytetyllä puoliautomaattisella menetelmällä ei pystytty vaikuttamaan omissiovirheiden määrään js näin ollen niiden vertailu ei olisi ollut hyödytöntä.

Puiden havaitsemistarkkuutta tarkasteltiin myös tutkimalla puulajin ja aluekohtaisen puiden keskiläpimitan vaikutusta automaattisen ja puoliautomaattisen menetelmän puiden havaitsemistarkkuuteen ja läpimitan mallinustarkkuuteen.

2.5.2 Läpimittaennusteiden tarkkuuden arviointi

ALS-aineistosta automaattisella ja puoliautomaattisella menetelmällä tuotetuille puille mallinnettiin läpimitat menetelmäkohtaisesti. Vertaamalla automaattisen ja puoliautomaattisen menetelmän läpimittaennusteita keskenään, saatiin tietoa menetelmien paremmuudesta.

Muodostettujen latvussegmenttien avulla ALS-aineistosta leikattiin jokaiselle havaitulle puulle latvussegmentin pinta-alaa vastaavat laserpisteet. Jokaisen latvussegmentin laserpistejoukolle laskettiin pisteiden jakaumaa kuvaavia ALS-piirteitä (esim. Yu ym. 2011). ALS-piirteitä olivat esimerkiksi korkeuspisteiden jakaumasta lasketut prosenttipisteet, korkeuden keskiarvo sekä suhteellisten korkeuksien keskihajonta. Prosenttipisteet ovat alhaaltapäin laskettuja laserpisteiden korkeusjakauman arvoja, jotka kertovat kuinka suuri kumulatiivinen osuus pisteistä on tietyllä korkeudella. Kaikki tutkimuksessa käytetyt ALS-piirteet on listattu liitteeseen 1. Läpimittoja mallinnettaessa käytettiin lähimmän naapurin menetelmää (kNN), jossa mittaamattomien puiden läpimitta ennustettiin viiden ALS-piirteiltään samankaltaisimman puun avulla. Lähimmän naapurin etsintään käytettiin ei-parametrasta Random Forest -menetelmää.

Random Forest (RF) on Breimanin (2001) kehittämä koneoppimismenetelmä, joka soveltuu hyvin metsätunnusten ennustamiseen vakautensa ja joustavuutensa ansiosta (Vastaranta ym. 2013). RF-algoritmi perustuu ns. regressiopuiden käyttöön. Nämä regressiopuut luokittelevat aineistoa jakamalla sitä useita kertoja osiin jonkin aineiston ominaisuuden perusteella. Regressiopuujoukko jaetaan satunnaisesti opetus- ja

testiaineistoon usein siten, että 2/3 osaa aineistosta toimii opetusaineistona ja 1/3 osaa testi aineistona. Lähimmän naapurin löytyminen RF-menetelmällä perustuu todennäköisyyteen päätyä regressiopuussa samaan loppusolmuun (Falkowski ym. 2010). kNN-menetelmissä valitaan aina, kuinka montaa lähintä naapuria jonkin muuttujan ennustamisessa käytetään (k-arvo). K-arvon määrittäminen on aina kompromissi, sillä pieni k-arvo kasvattaa satunnaisvirhettä, kun taas liian suuri k-arvo keskiarvoistaa tuloksia (Hudak ym. 2008). Tässä tutkimuksessa valittiin k-arvoksi 5 ja RF-mallinnukseen valikoituneet puut jaettiin satunnaisesti puoliksi opetus- ja testiaineistoon ja RF-ajo toistettiin 50 kertaa.

Läpimittojen mallinnukseen otettiin mukaan vain ne ALS-aineistosta tuotetut puut, jotka voitiin yhdistää yksiselitteisesti yhteen maastossa mitattuun referenssipuuhun. Tällöin latvussegmentit, joiden sisään rajautui vain yksi referenssipuu, otettiin mukaan läpimittojen estimointiin. Referenssipuut ja niitä vastaavat latvussegmentit valittiin puoliautomaattisella menetelmällä tuotetusta segmentointiaineistosta, jolloin samoille referenssipuille löytyi kummallakin menetelmällä tuotettu yksilöllinen latvussegmentti. Läpimitan mallinnukseen valikoitui näin ollen 1327 referenssipuuta ja niitä vastaavat automaattisella ja puoliautomaattisella menetelmällä tuotetut latvussegmentit.

Läpimittaennusteiden tarkkuuksia tarkasteltiin myös selvittämällä latvussegmenttien keskimääräisen poikkileikkauspinta-alan koon muuttuminen ja sen vaikutus läpimittaennusteiden tarkkuuteen siirryttäessä automaattisesta puoliautomaattiseen menetelmään. Tarkasteluun otettiin aineiston neljä yleisintä lehtipuuta ja kaksi yleisintä havupuuta.

Automaattisen ja puoliautomaattisen menetelmän läpimittaennusteita verrattiin maastossa mitattuihin referenssipuiden läpimittoihin ja läpimittaennusteiden tarkkuutta arvioitiin keskineliövirheen neliöjuuren (RMSE), (Yhtälöt 1 ja 2) ja harhan (Yhtälöt 3 ja 4) avulla.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}, \quad \text{Kaava 1}$$

$$RMSE \% = 100 * \frac{RMSE}{\bar{y}}, \quad \text{Kaava 2}$$

$$harha = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)}{n}, \quad \text{Kaava3}$$

$$harha \% = 100 * \frac{bias}{\bar{y}}, \quad \text{Kaava4}$$

joissa n on havaintojen määrä, y_i on mitattu arvo, \hat{y} on ennustettu arvo, \bar{y} on mitattujen arvojen keskiarvo.

3 TULOKSET


3.1 Puiden havaitsemistarkkuus

Maastossa mitattuja puita oli koko tutkimusalueella yhteensä 4365 (Taulukko 2). ALS-aineistosta automaattisella menetelmällä tuotettu puumäärä oli yhteensä 6860 ja puoliautomaattisella menetelmällä 3500. Automaattisella menetelmällä tuotetut puumäärät olivat Herttoniemen tutkimusaluetta lukuun ottamatta yliarvioita ja tutkimusalueiden yhteenlaskettu puumäärä automaattisella menetelmällä oli 57,2 %:n yliarvio referenssipuumäärään nähden. Kivelän, Koskelan ja Marian tutkimusalueilla puumäärät olivat automaattisella menetelmällä yli kaksinkertaiset verrattuna referenssipuumäärään. Puoliautomaattisella menetelmällä tuotetut puumäärät olivat Myllypuron tutkimusaluetta lukuun ottamatta aliarvioita ja tutkimusalueiden yhteenlaskettu puumäärä puoliautomaattisella menetelmällä oli 19,8 %:n aliarvio referenssipuumäärään nähden.

Taulukko 2. Tutkimusalueiden referenssipuumäärät, ALS-aineistosta automaattisella ja puoliautomaattisella menetelmällä tuotetut puumäärät ja menetelmien puumäärät suhteessa referenssipuumääriin. A = Automaattinen menetelmä ja P = Puoliautomaattinen menetelmä.

Tutkimusalue	Referenssi- puumäärä	A: Puumäärä	P: Puumäärä	A: Suhteellinen puumäärä, %	P: Suhteellinen puumäärä, %
Aurora	1567	1986	1226	126,7	78,2
Herttoniemi	122	118	73	96,7	59,8
Kivelä	415	869	396	209,4	95,4
Koskela	1025	2271	762	221,6	74,3
Laakso	843	1078	722	127,9	85,6
Malmi	172	201	141	116,9	82,0
Maria	77	157	60	203,9	77,9
Myllypuro	34	46	37	135,3	108,8
Suursuo	110	134	83	121,8	75,5
Yhteensä	4365	6860	3500	157,2	80,2

Parhaat suhteelliset puiden havaitsemistarkkuudet olivat ALS-aineistosta automaattisella menetelmällä tuotettu puumäärä Herttoniemen tutkimusalueella (96,7 %) ja puoliautomaattisella menetelmällä tuotettu puumäärä Kivelän tutkimusalueella (95,4 %) (Kuva 7). Kivelän, Koskelan ja Marian tutkimusalueilla automaattinen menetelmä tuotti yli 200 %:n yliarvion puumäärään. Suurimman aliarvion puiden määrään tuotti puoliautomaattinen menetelmä Herttoniemen tutkimusalueella (59,8 %). Merkittävin puiden havaitsemistarkkuuden parantuminen menetelmien välillä ilmeni Kivelän tutkimusalueella, jossa automaattisen menetelmän tuottama puumäärä oli yli kaksinkertainen (209,4 %) verrattuna referenssipuumäärään, mutta puoliautomaattisella menetelmällä päästiin hyvin lähelle referenssipuumäärää (95,4 %).




Kuva 7. ALS-aineistosta tuotettu puumäärä suhteessa referenssipuumäärään. Ympyröity 100 % on yhtä kuin referenssipuumäärä.

Automaattisen menetelmän tuottamista 6860 latvussegmentistä yhteensä 2561 sisälsi yhden tai useamman referenssipuun ja 4296 ei sisältänyt yhtään referenssipuuta. Puoliautomaattisen menetelmän tuottamista 3500 latvussegmentistä yhteensä 2332 sisälsi yhden tai useamman referenssipuun ja 1168 ei sisältänyt yhtään referenssipuuta (Taulukko 3). Näin ollen automaattisen menetelmän tuottamista latvussegmenteistä noin 66 % oli komissiovirheitä, kun taas puoliautomaattisen menetelmän tuottamista latvussegmenteistä noin 33 % oli komissiovirheitä. Suurin ero komissiovirheiden määrässä menetelmien välillä syntyi Koskelan tutkimusalueella, jossa komissiovirheiden määrä automaattisella menetelmällä (1613) oli yli kahdeksan kertainen puoliautomaattisen menetelmän (194) komissiovirhemäärään.

Taulukko 3. Tutkimusalueiden referenssipuumäärät, Automaattisesti ja puoliautomaattisesti tuotettujen latvussegmenttien kokonaismäärät ja komissiovirheiden määrät sekä komissiovirheiden osuus latvussegmenteistä. A = Automaattinen ja P = Puoliautomaattinen.

Tutkimusalue	Referenssi- puumäärä	A: Latvussegment- tejä yht. / komissiovirheitä	P: Latvussegment- tejä yht. / komissiovirheitä	A: Komissiovirhei- den osuus, %	P: Komissiovir- heiden osuus, %
Aurora	1567	1986/1167	1226/483	59	39
Herttoniemi	122	118/61	73/21	52	29
Kivelä	415	869/605	396/163	70	41
Koskela	1025	2271/1613	762/194	71	25
laakso	843	1078/567	722/233	53	32
Malmi	172	201/82	141/23	41	16
Maria	77	157/117	60/22	75	37
Myllypuro	34	46/23	37/14	50	38
Suursuo	110	134/61	83/15	46	18
Yhteensä	4365	6860/4296	3500/1168	63	33

Tutkimusalueiden keskiläpimitta vaihteli noin 15–30 cm välillä (Kuva 8). ALS-aineistosta puoliautomaattisella menetelmällä tuotetut puumäärät vaihtelivat noin 60–100 % välillä ja olivat keskimäärin noin 80 % referenssipuumäärästä kaikilla tutkimusalueilla. Automaattisella menetelmällä tuotetuissa puumäärissä oli havaittavissa suurempaa vaihtelua alueiden välillä. Marian, Koskelan ja Kivelän sairaala-alueilla, joissa puiden keskiläpimitta oli hieman alle 30 cm, olivat automaattisella menetelmällä tuotetut puumäärät yli kaksinkertaiset referenssipuumäärään nähden. Muilla alueilla automaattisen menetelmän tuottamat puumäärät olivat noin 100–130 % referenssipuumäärästä.



Kuva 8. Aluekohtainen puiden keskiläpimitta ja menetelmäkohtainen puumäärä suhteessa referenssipuumäärään. Ympyröity 100 % on yhtä kuin referenssipuumäärä.

3.2 Läpimittaennusteiden tarkkuus

Läpimittojen mallinnuksessa käytetty Rf-menetelmä laskee mallinnuksessa käytetyille ALS-piirteille niiden merkittävyyden. Kolme läpimittamallinnuksen merkittävintä piirrettä olivat: Kasvillisuus pisteiden määrä latvussegmentin sisällä (P_{no}), latvussegmentin sisällä olevien pisteiden virittämä pinta-ala xy-tasossa ($area_{chull}$) ja latvussegmentin sisällä olevien pisteiden virittämä tilavuus (vol_{alpha}). Kaikkien piirteiden merkitsevyystaulukko on liitteessä 2.

Automaattisella menetelmällä läpimittaennusteiden absoluuttinen RMSE oli 12,84 cm ja suhteellinen RMSE 41,8 % (Taulukko 4). Puoliautomaattisella menetelmällä läpimittaennusteiden absoluuttinen ja suhteellinen RMSE olivat 10,99 cm ja 35,8 %. Siirryttäessä automaattisesta puoliautomaattiseen menetelmään, läpimittaennusteet tarkentuivat absoluuttisesti 1,85 cm ja suhteellisesti 6 %-yksikköä.

Taulukko 4. ALS-aineistosta tuotettujen puiden läpimittaennusteiden RMSE:n ja harhan määrät.

Menetelmä	RMSE, cm	RMSE, %	Harha, cm	Harha, %
Automaattinen	12,84	41,8	0,18	0,6
Puoliautomaattinen	10,99	35,8	0,16	0,5
4 yleisintä puulajia, Automaattinen Puoliautomaattinen	12,54 10,29	38,8 31,9	- 0,73 0,05	- 2,3 0,1

Aineiston neljän yleisimmän puulajin kohdalla puoliautomaattisen menetelmän läpimittaennusteet olivat absoluuttisesti 2,25 cm ja suhteellisesti 7,1 %-yksikköä tarkempia. Tutkimusalueiden neljän yleisimmän puulajin, joita olivat rauduskoivu, vaahtera, haapa ja mänty, osuus referenssipuista oli 63 % ja läpimittamallinnukseen valikoituneista puista 68 %.


Läpimittaennusteiden harhan määrät olivat hyvin vähäisiä koko aineiston kohdalla, eikä niissä ollut menetelmien välillä juurikaan eroa. Neljän yleisimmän puulajin kohdalla automaattisen menetelmän läpimittaennusteen absoluuttinen ja suhteellinen harha (-0,73 cm ja -2,3 %) olivat hieman suurempia, kuin puoliautomaattisen menetelmän vastaavat harhan määrät (0,05 cm ja 0,1 %).

Automaattisen ja puoliautomaattisen menetelmän läpimittaennusteiden absoluuttinen RMSE kasvoi systemaattisesti läpimittaluokan kasvaessa, poikkeuksena puoliautomaattisen menetelmän 30–40 cm läpimittaluokka (Taulukko 5). Kummankin menetelmän läpimittaennusteiden harha oli pienissä läpimittaluokissa negatiivinen ja suurissa positiivinen. Pienin harhan määrä kummallakin menetelmällä saavutettiin 30–40 cm läpimittaluokassa, jossa absoluuttinen ja suhteellinen harha olivat automaattisella menetelmällä -1,3 cm ja -4 % ja puoliautomaattisella menetelmällä 0,4 cm ja 1 %. Suurimmat suhteelliset harhan määrät olivat pienimmässä 5–10 cm ja suurimmassa 120–130 cm läpimittaluokissa. Suurin läpimittaennusteen absoluuttinen tarkentuminen siirryttäessä automaattisesta puoliautomaattiseen menetelmään ilmeni 60–70 cm läpimittaluokassa, jossa puoliautomaattisen menetelmän läpimittaennusteen absoluuttinen RMSE oli 7,8 cm pienempi kuin automaattisen menetelmän.

Taulukko 5. Läpimittaennusteiden RMSE:n ja harhan määrät läpimittaluokittain ja menetelmäkohtaisesti.

Läpimitta- luokka, cm	Automaattinen menetelmä				Puoliautomaattinen menetelmä			
	RMSE, cm	RMSE, %	Harha, cm	Harha, %	RMSE, cm	RMSE, %	Harha, cm	Harha, %
5-10	9.5	131	-4.8	-66	8.7	120	-4.2	-59
10-20	10.6	71	-5.0	-34	9.2	62	-3.9	-26
20-30	11.4	45	-3.8	-15	10.0	40	-1.9	-7
30-40	10.3	29	-1.3	-4	9.5	27	0.4	1
40-50	10.7	24	2.4	5	10.0	22	1.9	4
50-60	14.6	27	9.8	18	11.9	22	6.4	12
60-70	20.5	32	16.8	26	12.7	20	8.1	13
70-80	29.7	41	26.5	36	23.1	32	17.1	23
80-90	37.4	44	35.2	41	31.5	37	28.6	34
90-100	20.1	21	19.1	20	22.9	24	21.7	22
100-110	-	-	-	-	-	-	-	-
110-120	68.6	60	65.9	57	61.6	54	60.5	53
120-130	80.1	64	79.9	64	77.5	62	77.2	62

Läpimittaennusteiden suhteellinen RMSE oli kummallakin menetelmällä selkeästi suurin 5–10 cm läpimittaluokassa, ollen automaattisella menetelmällä 131 % ja puoliautomaattisella 120 % (Kuva 9). Suhteellinen RMSE pienentyi automaattisella menetelmällä 40–50 cm läpimittaluokkaan asti ja puoliautomaattisella menetelmällä 60–70 cm läpimittaluokkaan asti. Automaattisen menetelmän läpimittaennusteiden suhteellinen RMSE alkoi jälleen kasvamaan 40–50 cm läpimittaluokan jälkeen ja puoliautomaattisella menetelmällä 60–70 cm läpimittaluokan jälkeen. Poikkeus suhteellisessa RMSE:n kasvussa oli 90–100 cm läpimittaluokka. Suurin läpimittaennusteen suhteellinen tarkentuminen ilmeni 60–70 cm läpimittaluokassa, jossa se tarkentui 12 %-yksikköä siirryttäessä automaattisesta puoliautomaattiseen menetelmään.



Kuva 9. Automaattisen ja puoliautomaattisen menetelmän läpimittaennusteiden suhteellinen RMSE läpimittaluokittain.

Taulukossa 6 on läpimitan mallinnusaineistoon valikoituneet kolme yleisintä lehtipuuta ja kaksi yleisintä havupuuta. Siirryttäessä automaattisesta puoliautomaattiseen menetelmään latvussegmenttien keskimääräinen poikkileikkauspinta-ala kasvoi rauduskoivulla 65,1 %, vaahteralla 72,2 % ja haavalla 18,6 %. Männyllä latvussegmenttien poikkileikkauspinta-ala kasvoi vastaavasti 24,2 % ja kuusella vain 2,1 %. Suurin läpimitan suhteellinen tarkentuminen siirryttäessä automaattisesta puoliautomaattiseen menetelmään saavutettiin lehtipuista haavalla (12 %-yksikköä) ja rauduskoivulla (10 %-yksikköä). Männyksen läpimitta tarkentui 3 %-yksikköä ja kuusen kohdalla yllättäen automaattisen menetelmän läpimitta oli 7,7 %-yksikköä tarkempi.

Taulukko 6. Puulajikohtainen keskiläpimitta, läpimittaennusteiden RMSE, keskimääräinen latvussegmenttien poikkileikkauspinta-ala ja latvussegmenttien poikkileikkauspinta-alan suhteellinen kasvu siirryttäessä automaattisesta puoliautomaattiseen menetelmään. A = Automaattinen menetelmä, P = Puoliautomaattinen menetelmä.

Puulaji (Keskiläpimitta, cm)	A: RMSE, %	P: RMSE, %	A: Keskimääräinen latvussegmentin pinta-ala, m²	P: Keskimääräinen latvussegmentin pinta-ala, m²	Latvusseg- menttien pinta-alan kasvu, %
Rauduskoivu (32,7)	38,4	28,4	31,7	52,4	65,1
Vaahtera (32,7)	42,6	35,7	35,9	61,9	72,2
Haapa (18,4)	57,9	45,9	22,6	26,8	18,6
Mänty (37,4)	32,2	29,2	32,2	40,0	24,2
Kuusi (25,9)	34,7	42,4	22,2	22,7	2,1

4 TULOSTEN TARKASTELU

4.1 Puiden havaitsemistarkkuuden tarkastelu

Tutkimuksen tavoitteena oli selvittää, onko puistopuiden kartoitustarkkuutta mahdollista parantaa puoliautomaattisesti tuotetulla latvuskartalla ja ensimmäisessä osatarkastelussa menetelmien välistä kartoitustarkkuutta arvioitiin määrittämällä puiden havaitsemistarkkuus ALS-aineistosta menetelmäkohtaisesti. Selvyiden vuoksi on hyvä vielä huomioda, että tutkimuksen puiden havaitsemistarkastelussa lähtöoletuksena oli, että jokainen latvussegmentti vastaa yhtä ALS-aineistosta tuotettua puuta.

Kuten tuloksista käy ilmi, automaattisen menetelmän tuottama puumäärä oli 57,2 % yliarvio referenssipuumäärään nähden ja puoliautomaattisen menetelmän tuottama puumäärä oli 19,8 % aliarvio referenssipuumäärään nähden. Näin ollen puiden havaitsemistarkkuus parani 37,4 %-yksikköä siirryttäessä automaattisesta menetelmästä puoliautomaattiseen menetelmään. Automaattinen latvussegmentointi tuotti odotetusti hyvin runsaasti ylimääräisiä latvussegmenttejä ja yliarvioi näin ollen puiden määrän. Kun näitä automaattisen menetelmän tuottamia ylimääräisiä latvussegmenttejä yhdistettiin

puoliautomaattisesti, saatiin latvussegmenttien määrä putoamaan automaattisen menetelmän 6860 latvussegmentistä puoliautomaattisen menetelmän 3500 latvussegmenttiin.

Automaattisen menetelmän tuottaman puiden suuren yliarvion (57,2 %) voidaan katsoa johtuneen leveälatvuksisten puiden ja erityisesti monihaaraisten lehtipuiden jakautumisesta useaan eri latvussegmenttiin. Suurien lehtipuiden ylisegmentoituminen on tullut selkeästi esiin myös monissa aikaisemmissa yksinpuintulkintamenetelmiä hyödyntävissä kaupunkipuiden kartoitustutkimuksissa (esim. Höfle ym. 2012, Zhang ym. 2015, Tanhuanpää ym. 2019).

Puoliautomaattisen menetelmän tuottaman puumäärän aliarvion (19,8 %) voidaan olettaa johtuneen suurelta osin kahdesta seikasta. Suurien leveälatvuksisten puiden alle jää pieniä puita, joita ei havaittu ALS-aineistosta automaattisesti tuotetulla latvussegmentoinnilla, eikä tähän ongelmaan pystytty vaikuttamaan puoliautomaattisella menetelmällä. Toinen puiden määrää aliarvioiva tekijä oli tiheäpuustoiset alueet, joissa puiden latvuksia sulautui samoihin latvussegmentteihin ja näiden tiheäpuustoisten alueiden puoliautomaattinen muokkaus oli suurelta osin mahdotonta. Kun osa referenssipuista jäi edellä mainittujen syiden takia havaitsematta, mutta automaattisen menetelmän tuottamia ylimääräisiä leveälatvuksista puista muodostuneita latvussegmenttejä pystyttiin yhdistämään, putosi puoliautomaattisen menetelmän puiden havaitsemisprosentti alle referenssipuumäärän.

Automaattisella menetelmällä aiheutunut latvusten ylisegmentoituminen on erityisen hyvin nähtävissä menetelmäkohtaisten komissiovirheiden määrissä (Taulukko 3). Automaattisen menetelmän tuottamista latvussegmenteistä jopa 63 % oli komissiovirheitä, eikä sisältänyt yhtään referenssipuuta, kun taas puoliautomaattisen menetelmän tuottamista latvussegmenteistä 33 % oli komissiovirheitä. Automaattisen menetelmän komissiovirheiden (4296) määrä oli lähes nelinkertainen verrattuna puoliautomaattiseen menetelmään (1168). Voidaankin todeta, että yksi suurin parannus puoliautomaattisella latvussegmentointimenetelmällä saavutettiin juuri komissiovirheiden huomattavasti pienemmässä määrässä, sillä komissiovirheet yliarvioivat havaittujen puiden määrää. Kun puustoltaan ja puustotiheydeltään monimuotoisella kaupunkipuualueella arvioidaan latvussegmentoinnin onnistumista ja

kykyä havaita puita, on komissiovirheiden määrä yksi hyvä indikaattori latvussegmentoinnin onnistumiselle.

Suurien puiden ylisegmentoituminen automaattisella menetelmällä huomataan myös verrattaessa tutkimusalueiden puuston keskiläpimittoja ja aluekohtaisia automaattisen menetelmän tuottamia suhteellisia puumääriä (Kuva 5). Koskelan, Laakson ja Marian tutkimusalueilla, joissa puiden keskiläpimitta oli lähes 30 cm, oli automaattisen menetelmän tuottama puumäärä yli 200 % referenssipuumäärästä. Muilla tutkimusalueilla, joissa puiden keskiläpimitta vaihteli 15–20 cm välillä, putosi automaattisen menetelmän tuottama puumäärä 100–130 %:iin referenssipuumäärästä. Myllypuron tutkimusalueella, jossa puiden keskiläpimitta oli suurin (31,1 cm), huomataan automaattisen menetelmän tuottaman suhteellisen puumäärän (135 %) olevan odotettua pienempi yliarvio. Tämän voidaan olettaa johtuvan Myllypuron tutkimusalueen harvassa kasvavasta ja vähälukuisesta mäntyvaltaisesta puustosta, jossa 34 puusta 29 oli mäntyjä. Havupuun latvus on yleensä lehtipuuta säännönmukaisempi ja kapeampi (Zhang ym. 2015). Tämän voidaankin katsoa olevan yksi syy automaattisen latvussegmentoinnin onnistumiseen havupuiden kohdalla lehtipuita paremmin.

Puulajin vaikutus latvussegmentoinnin tuloksiin on huomattavissa, kun verrataan puulajikohtaisia latvuksien poikkileikkauspinta-alojen kokoa menetelmien välillä (Taulukko 6). Lehtipuista rauduskoivun ja vaahteran latvussegmenttien poikkileikkauspinta-alat olivat puoliautomaattisella menetelmällä noin 65 % ja 72 % suurempia kuin automaattisen menetelmän. Männyn latvussegmenttien poikkileikkauspinta-ala oli puoliautomaattisella menetelmällä noin 24 % suurempi ja kuusella vain noin 2 %, kuin automaattisella menetelmällä. Voidaankin todeta, että havupuiden, varsinkaan kuusen kohdalla, latvussegmenttien puoliautomaattinen muokkaus ei ollut yhtä tarpeellista kuin lehtipuiden.

Tämän tutkimuksen puidenhavaitsemistarkkuutta vertailtaessa aikaisempiin kaupunkipuiden kartoitusta koskeviin yksinpuintulkintatutkimuksiin on syytä huomioida menetelmä, jolla tutkimuksen puiden havaitsemista tarkastellaan. Tässä tutkimuksessa puiden havaitsemistarkkuutta arvioitiin vertaamalla suoraan latvussegmenttimääriä referenssipuiden määriin. Useimmissa vastaavista kaupunkipuiden yksinpuintulkintaa käsittelevistä tutkimuksista puiden havaitsemista on tarkasteltu eri periaatteella. Näissä

tutkimuksissa ALS-aineistosta rajatut latvukset on yhdistetty referenssipuihin ja arvioitu referenssipuiden havaitsemista puutasolla (esim. Holopainen ym. 2013, Liu ym. 2013, Tanhuanpää ym. 2014, Zhang ym. 2015, Matasci ym. 2018).

Zhang ym. (2015) saivat kaupunkipuiden kartoitustutkimuksessaan puiden havaitsemisprosentiksi 93,5 %. Tutkimuksessa hyödynnettiin ilmakehän ja ALS-aineiston yhdistelmää ja tutkimus perustui 3D-pistepilvimenetelmään. Tutkimuksessa määritettiin myös komissiovirheiden määrä. Omissio- ja komissiovirheet määritettiin menetelmällä, jossa jokainen sellainen referenssipuu laskettiin havaituiksi, joka oli korkeintaan 5 m päässä ALS-aineistosta havaitusta puusta tai ALS-aineistosta havaitun puun latvuksen sisäpuolella. Referenssipuut, joita ei löytynyt ALS-aineistosta, laskettiin omissiovirheiksi ja mikäli ALS-aineistolta havaitulle puulle ei löytynyt referenssipuuta laskettiin se komissiovirheeksi. Tällä menetelmällä tutkimuksen omissiovirheeksi saatiin 9,4 % ja komissiovirheeksi 24,3 %. Tutkimuksessa komissiovirheiden määrää arvioitiin vertaamalla sitä referenssipuumäärään. Mikäli tämän tutkimuksen komissiovirheiden määrää verrataan referenssipuumäärään, saadaan puoliautomaattisen menetelmän komissiovirheeksi 26,8 % ja automaattisen menetelmän komissiovirheeksi jopa 98,4 %. Tutkimusten komissiovirheiden määrät eivät kuitenkaan ole suoraan verrattavissa sillä tutkimuksissa käytetyt yksinpuintulkintamenetelmät olivat hyvin erilaiset.

Tanhuanpää ym. 2014 saivat Helsingin katupuututkimuksessaan puiden havaitsemisprosentiksi 88,8 %. Tutkimuksessa puiden latvukset rajattiin latvuston pintamallista valuma-aluesegmentoinnilla, joten tutkimuksen ALS-aineistosta tuotetussa puukartan luonnissa käytettiin samaa latvussegmentointimenetelmää, kuin tässä tutkimuksessa. Tutkimuksessa havaituiksi puiksi laskettiin vain sellaiset referenssipuut, joille löytyi yksilöllinen latvussegmentti. Tämän tutkimuksen puiden havaitsemistarkkuudessa ei yletty samalle tasolle. Tämän voidaan olettaa johtuvan ainakin osittain tämän tutkimuksen hyvin monimuotoisesta puuston rakenteesta ja puiden vaihtelevuudesta yksittäisistä katu- ja puistopuista aina tiheisiin metsäalueiden puihin.

Tämän tutkimuksen puidenhavaitsemistarkkuutta arvioitaessa on hyvä huomioda, että tutkimuksen tavoitteena oli verrata automaattisen ja puoliautomaattisen menetelmän puiden kartoitustarkkuutta keskenään ja selvittää onko puiden kartoitusta mahdollista parantaa puoliautomaattisella menetelmällä. Näin ollen tämän tutkimuksen puiden

havaitsemistarkkuuden vertailu muihin vastaaviin kaupunkipuiden kartoitusta käsitteleviin tutkimuksiin ei välttämättä ollut niinkään tarpeellista.

4.2 Läpimittaennusteiden tarkkuuden tarkastelu

Tutkimuksen toisessa osatarkastelussa automaattisen ja puoliautomaattisen menetelmän kartoitustarkkuutta vertailtiin mallintamalla ALS-aineistosta tuotetuille puille läpimitta menetelmäkohtaisesti.

Puiden havaitsemistarkkuuden ohella myös läpimittaennusteiden tarkkuus parani siirryttäessä automaattisesta puoliautomaattiseen menetelmään. Koko aineiston läpimittaennusteet tarkentuivat puoliautomaattisella menetelmällä 6 %-yksikköä ja neljän yleisimmän puulajin kohdalla 7,1 %-yksikköä (Taulukko 4). Aineiston kolmen selkeästi yleisimmän lehtipuun kohdalla puoliautomaattisen menetelmän läpimittaennusteet tarkentuivat rauduskoivulla 10 %-yksikköä, vaahteralla 6,9 %-yksikköä ja haavalla noin 12 %-yksikköä (Taulukko 6). Aineiston yleisimmällä havupuulla männyllä, läpimittaennuste tarkentui vain noin 3 %-yksikköä ja kuusella yllättäen automaattinen menetelmä tuotti lähes 7,7 %-yksikköä tarkemman läpimittaennusteen.

Lehtipuiden läpimittaennusteiden tarkentuminen puoliautomaattisella menetelmällä oli odotettua, sillä lehtipuiden latvusten poikkileikkauspinta-alat olivat puoliautomaattisella menetelmällä huomattavasti suurempia kuin automaattisella menetelmällä. Esimerkiksi koivun keskimääräinen latvussegmentin pinta-ala oli puoliautomaattisella menetelmällä noin 65 %-yksikköä ja vaahteralla yli 72 %-yksikköä suurempi (Taulukko 6). Puoliautomaattisen muokkauksen jälkeen latvussegmenttien koko vastasi paremmin todellisia puiden latvuksia ja näin ollen läpimittamallinnus tuotti odotetusti tarkempia tuloksia puoliautomaattisella menetelmällä. Läpimittoja mallinnettiin käyttämällä lähimmän naapurin menetelmää, jossa mittaamattomien puiden läpimitta ennustettiin viiden ALS-piirteiltään samankaltaisimman puun avulla, joten mitä lähempänä saman paksuisten ja pituisten puiden latvussegmenttien koko oli toisiaan, sitä tarkempia voitiin olettaa myös läpimittaennusteiden olevan.

Kuusien automaattisen menetelmän tarkemman läpimittaennusteen voidaan olettaa ainakin osittain johtuneen siitä, että automaattisen menetelmän lehtipuiden

latvussegmentit olivat kooltaan lähempänä kuusien latvussegmenttejä kuin puoliautomaattisen menetelmän lehtipuiden latvussegmentit. Kuusia oli valikoitunut läpimitan mallinnusaineistoon vain 26 ja ei-parametrinen Rf- ja kNN-menetelmä tuottivat sitä tarkempia läpimittaennusteita, mitä enemmän samankaltaisia puita aineistossa oli (Tanhuanpää ym. 2019). Puoliautomaattisella menetelmällä yhdistettiin lehtipuiden latvussegmenttejä, jolloin niiden latvussegmenttien koko kasvoi ja kuusien latvussegmenttien koko pysyi lähes ennallaan. Näin ollen puolialtomaattisesti tuotetussa aineistossa kuusien latvussegmenttien kanssa samankokoiset latvussegmentit vähenivät huomattavasti ja tämän voidaan katsoa olevan yksi mahdollinen syy, miksi läpimittaennusteiden tarkkuus kuusien kohdalla heikentyi puolialtomaattisella menetelmällä.

Kun läpimittaennusteita tarkastellaan läpimittaluokittain huomataan, että absoluuttinen RMSE kasvoi systemaattisesti läpimittaluokan kasvaessa, mutta suhteellinen RMSE oli selkeästi suurin pienimmässä 5-10 cm läpimittaluokassa. Suhteellinen läpimittaennusteiden RMSE oli pienimmillään 30–70 cm läpimitaltaan olleilla puilla. Suurimmissa 110-120 cm ja 120-130 cm läpimittaluokissa suhteellinen RMSE nousi yli 50 % molemmilla menetelmillä. Absoluuttinen läpimittaennusteen virheen kasvu selittyy luonnollisesti sillä, että puun läpimitan kasvaessa myös läpimittaennusteen absoluuttinen virhe hyvin todennäköisesti kasvaa. Aineiston pienimpien puiden korkean suhteellisen läpimittaennusteen RMSE:n voidaan katsoa johtuvan kahdesta seikasta. Pienillä puilla läpimittaennusteiden pienikin virhe vaikuttaa suhteellisesti enemmän suuriin puihin verrattuna. Toisen syyn voidaan nähdä johtuvan läpimittamallinnuksessa käytetystä kNN-menetelmästä. Kun läpimittoja ennustetaan samankaltaisimpien puiden avulla, ei ääriarvoja koskaan saavuteta (Tanhuanpää ym. 2014). Samasta syystä myös suurimmissa läpimittaluokissa suhteellinen läpimittaennusteen RMSE oli suuri. Suurien puiden läpimittaennusteen korkean suhteellisen RMSE -arvon voidaan olettaa johtuvan myös siitä, että suuria puita oli läpimitan mallinnusaineistossa hyvin vähän, jolloin aineistossa ei ole riittävästi samankaltaisia puita luotettavan läpimittaennusteen saamiseksi.

Pienien puiden kohdalla saatu läpimittaennusteen negatiivinen harha kertoo läpimittamallinnuksen yliarvioineen pienien puiden läpimittaa ja suurempien puiden positiivinen harha kertoo läpimittamallinnuksen aliarvioineen suurien puiden läpimittaa. Tämän voidaan katsoa jälleen johtuvan läpimitan mallinnuksessa käytetystä kNN-

menetelmästä, jolla ei saavuteta aineiston ääriarvoja ja joka suurilla k :n arvoilla keskiarvoistavastaa tuloksia (Hudak ym. 2008).

Shrestha ja Wynne (2012) saivat Oklahoman lentotukikohdassa katu- ja puistopuiden kartoitusta käsittelevässä tutkimuksessaan läpimitan absoluuttiseksi RMSE -arvoksi 11,2 cm. Tutkimuksessa puiden latvukset rajattiin manuaalisesti ALS-aineistoa ortoilmakuvia hyväksi käyttäen ja puiden läpimitta ennustettiin luomalla lineaarinen regressiomalli maastossa mitattujen puiden läpimittojen ja ALS-aineiston laserpistepilven korkeuspistejakaumasta laskettujen keskiarvojen välille. Tämän tutkimuksen automaattisen ja puoliautomaattisen menetelmän läpimittaennusteiden absoluuttisten RMSE-arvojen (12,84 cm ja 10,99cm) nähdään olevan saman suuntaisia. Vertailussa pitää kuitenkin huomioda, että tässä tutkimuksessa puiden latvukset rajattiin eri menetelmällä ja läpimitan mallinnusmenetelmänä käytettiin ei-parametrista Rf- ja kNN-menetelmää.

Tässä tutkimuksessa saatujen läpimittaennusteiden tarkkuuksissa ei ylletty samalle tasolle aikaisempien Helsingin kaupunkipuita koskevien ALS-aineistoa ja yksinpuintulkintamenetelmiä hyödyntävien tutkimuksien kanssa, joissa latvuksenrajausmenetelmät ja läpimitan mallinnusmenetelmät olivat vastaavat tämän tutkimuksen kanssa. Tanhuanpää ym. (2014) saivat Helsingin katupuukartoitustutkimuksessaan läpimittaennusteiden RMSE -arvoksi 6,9 cm ja Saarinen ym. (2014) saivat Helsingin kaupunkipuita koskevassa tutkimuksessaan puiden läpimittaennusteiden RMSE -arvoksi 6,85 cm metsäisellä alueella ja 7,09 cm puistomaisella alueella.

Tässä tutkimuksessa saatujen läpimittaennusteiden heikomman tarkkuuden voidaan katsoa ainakin osittain johtuneen tutkimusalueen puulajien, puustotiheyden ja puiden kokorakenteen suuresta vaihtelevuudesta. Tutkimusalue sisälsi vaihtelevasti yksittäisiä katupuita, harvapuustoisia puistoalueita ja tiheäpuustoisia metsäalueita. Läpimitan mallinnukseen valikoituneiden puiden läpimitat vaihtelivat 5–125 cm välillä ja puiden keskiläpimitta oli 30,7 cm. Puiden läpimittojen erittäin suuresta vaihtelevuudesta ja korkeasta keskiläpimitasta johtuen on luonnollista, että myös läpimittaennusteiden RMSE on suuri.

Tässä tutkimuksessa läpimittaennusteiden tarkkuuden arviointi otettiin tutkimukseen

mukaan yhdeksi tavaksi vertailla automaattisen ja puoliautomaattisen menetelmän puiden kartoitustarkkuutta, eikä tutkimuksen tavoitteena ollut löytää optimaalista puiden kartoitusmenetelmää tai läpimitan mallinnusmenetelmää. Tämän vuoksi ei vertailu muiden vastaavien tutkimuksien tuloksiin ollut niin oleellista työn kannalta.

4.3 Puoliautomaattisen latvussegmentointimenetelmän tarkastelu

Ilmakuvien määrällä, laadulla ja sillä mihin vuoden aikaan ilmakeku oli otettu, oli suuri merkitys visuaaliseen latvussegmenttien muokkaukseen. Tietyn puun rungon ja latvuksen vertailu usealta eri ilmakekulta helpotti ALS-aineistosta tuotettujen latvussegmenttien ja ilmakekulta erottuvien latvuksen yhteen sovittamista ja muokkausta. Puiden silmävarainen määrän arviointi ja latvussegmenttien muokkaus ilmakekulta osoittautui tiheissä latvustoissa paikoitellen hyvin haastavaksi ja näillä alueilla muokkausta ei välttämättä ollut järkevää tehdä ollenkaan (kuva 6). Mitä harvemmassa puut kasvoivat, sitä helpompaa latvussegmenttien muokkaus oli, sillä yksittäin kasvavien puiden latvukset erottuivat selkeästi toisistaan. Parhaiten puiden yksilöinti ja puiden määrän arviointi onnistui lehdettömään aikaan otetuista ilmakekusta, joissa puiden rungot tai niistä muodostuneet varjot olivat selkeästi nähtävissä. Lehdettömään aikaan otetuista ilmakekusta oli myös helpointa erottaa puiden latvakohdat ja verrata niitä ALS-aineistosta muodostuneisiin latvapisteisiin. Lehdelliseen aikaan otetuista ilmakekusta pystyi latvukset erottamaan, mikäli ne olivat selkeästi eri vihreänsävyisiä tai latvusten varjot eri korkeudella, mutta puiden latvakohtaa niistä oli vaikea määrittää.



Kuva 6, vasemmalla harvassa kasvavien puistopuiden puolialtomaattisesti tuotettu latvussegmentointi Koskelan tutkimusalueella ja oikealla tiheäpuustaisen metsäalueen puolialtomaattisesti tuotettu latvussegmentointi Auroran tutkimusalueella.

Suurien yksittäisten puiden erottaminen ilmakuvista oli luonnollisesti helpompaa kuin pienien puiden, jotka saattoivat olla osittain tai kokonaan suurempien puiden alla. Usean eri ilmakuvan ja suodattamattoman latvuston pintamallin tarkastelu ja vertailu auttoi hahmottamaan puiden todellisen määrän ja latvuston rakenteen. Yleisesti ottaen voidaankin todeta, että mitä suurempi määrä eri vuodenaikoina otettuja ilmakuvia on käytettävissä, sitä parempaan lopputulokseen puoliautomaattisella menetelmällä päästään, mutta toisaalta usean ilmakuvan vertailu ja tutkiminen hidastaa muokkausprosessia.

4.4 Tutkimuksen mahdollisia virhelähteitä

Ensinnäkin on huomioitava, että ALS-aineistosta tuotetun latvussegmentoinnin visuaalinen muokkaus on aina subjektiivinen tulkinta, jolloin tuloksissa esiintyy jonkin verran tekijästä johtuvaa vaihtelua.

Puiden sijainnin GPS-mittauksessa oli jonkin verran sijaintivirhettä, joka on voinut varsinkin tiheäpuustoisilla alueilla aiheuttaa joidenkin referenssipuiden yhdistymisen väärään latvussegmenttiin. Ortoilmakuvien projektiovirheet aiheuttivat paikoitellen lieviä vinoumia ja vääristymiä puiden todellisiin sijainteihin, jolloin ALS-aineistosta muodostunut puun latvus ja latvapiste saattoivat olla eri paikassa, kuin ilmakuvasta erottuva latvus ja sen arvioitu huippukohta. Tämä hankaloitti latvussegmenttien muokkausta ja saattoi aiheuttaa virhettä latvussegmenttien tulkintaan.

ALS-aineistosta leikattiin pois kaikki pisteet alle 2,5 metristä maan pinnasta, jotta latvussegmenttejä muodostuisi mahdollisimman vähän puskista, pensaista ja alle 5 cm läpimitaltaan olevista puista. On kuitenkin selvää, että osa alle 5 cm rinnankorkeusläpimitaltaan olevista puista on yli 2,5 metriä pitkiä ja toisaalta pieni osa yli 5 cm läpimitaltaan olevista puista on todennäköisesti ollut alle 2,5 metriä pitkiä. Tämä aiheuttaa pienien puiden osalta virhettä puiden havaitsemiseen ALS-aineistosta. Referenssipuiden suuresta määrästä johtuen niistä ei mitattu pituutta, joten referenssipuiden pituuksien vaikutusta tutkimuksen tuloksiin ei käsitelty.

Yksi puiden havaitsemiseen virhettä aiheuttava tekijä oli myös tutkimuksessa käytettyjen aineistojen eriaikaisuus. ALS-aineisto oli vuodelta 2017 ja maastomittaukset suoritettiin kesällä 2019. Mikäli ALS-aineisto olisi myös ollut vuodelta 2019, puut olisivat olleet

ALS-aineistoa prosessoidessa pidempiä ja näin ollen latvussegmenttejä olisi muodostunut hieman enemmän ja mahdollisesti pienistä puista hieman suurempi osa olisi tullut näin ollen havaituksi. Aineistojen eriaikaisuus vaikutti myös läpimitan mallinnukseen, mutta tutkimuksessa oli kuitenkin tarkoitus verrata läpimitan mallinnustarkkuutta automaattisen ja puoliautomaattisen menetelmän välillä ja aineistojen pysyessä samana eri menetelmiä testattaessa, ei aineistojen eriaikaisuudella ollut niinkään merkitystä menetelmien eroa arvioitaessa.

Puiden epäsymmetrinen runkomuoto voi myös aiheuttaa virhettä läpimittaennusteisiin. Puun runko ei ole koskaan täysin pyöreä, jolloin puun läpimitta vaihtelee jonkin verran mittauskohdasta riippuen. Varsinkin iäkkäiden ja suurien puistopuiden runkomuoto voi olla hyvin epäsymmetrinen ja eri kohdista mitattuihin läpimittoihin voi näin ollen tulla huomattavan suuria eroja (Saarinen, 2014).

5 JOHTOPÄÄTÖKSET

Tutkimuksen tavoitteena oli selvittää, onko puistopuiden kartoitustarkkuutta mahdollista parantaa puoliautomaattisesti tuotetulla latvuskartalla. Kuten tulokset osoittivat puiden havaitsemistarkkuus ja puiden läpimittaennusteet tarkentuivat puoliautomaattisella menetelmällä ja näin ollen voidaan todeta puiden kartoitustarkkuuden parantuneen puoliautomaattisesti tuotetulla latvuskartalla. Puoliautomaattisella menetelmällä pystyttiin vaikuttamaan erityisesti lehtipuiden ylisegmentoitumiseen ja vähentämään huomattavasti komissiovirheiden määrää. Visuaalisen tarkastelun ja latvussegmentoinnin muokkauksen voidaan kuitenkin todeta olleen paikoitellen kohtalaisen työlästä ja sen hyödyllisyyttä tuleekin arvioida vertaamalla työmäärää suhteessa siitä saatavaan hyötyyn. Kookkaita ja harvakseltaan kasvavia puita sisältävillä puistomaisilla alueilla puolialtomaattinen latvussegmentoinnin muokkaus osoittautui selkeästi helpoimmaksi sekä vähiten aikaa ja työtä vaativaksi. Tiheäpuustoisilla metsäalueilla muokkaus taas oli työlästä ja haastavaa. Tämän perusteella voidaankin todeta, että puolialtomaattinen menetelmä soveltui hyvin harvapuustoisille puistoalueille, mutta tiheäpuustoisilla metsäalueilla latvussegmentoinnin muokkauksella ei saavutettu merkittävää hyötyä.

Puoliautomaattisen latvussegmenttien muokkauksen kannattavuus riippui myös kohteessa kasvavista puulajeista. Suurin hyöty saavutettiin suurilla avoimella alueilla kasvavilla lehtipuilla, joiden latvus oli leveä ja jakautui kauas rungosta kasvaviin järeisiin oksahaaroihin. Ortoilmakuvista ja latvuston pintamallista oli useimmissa tapauksissa helppo erottaa lehtipuiden oksahaaroista muodostuneet erilliset latvussegmentit, joiden yhdistäminen puoliautomaattisilla menetelmillä toisiinsa oli vaivatonta ja suhteellisen nopeaa. Havupuiden kohdalla automaattinen latvussegmentointi tuotti paremman tuloksen ja muokkaus ei näin ollen ollut yhtä tarpeellista, kuin lehtipuilla. Tämän tutkimuksen perusteella voidaan todeta, että ALS-aineistosta luodun latvuskartan puoliautomaattinen muokkaus voisi olla hyödyllistä operatiivisessa kaupunkipuukartoituksessa erityisesti puistomaisilla alueilla.

6 LÄHTEET

Alonzo M., Bookhagen B., Roberts D. 2014. Urban tree species mapping using hyperspectral and lidar data fusion. *Remote Sensing of Environment* 148: 70-83.

Ardila, J.P., Bijker, W., Tolpekin, V.A. ja Stein, A. 2012. Context-sensitive extraction of tree crown objects in urban areas using VHR satellite images. *International Journal of Applied Earth Observations and Geoinformation*. Vol. 15. p. 57–69. ISSN 0303-2434.

Bolund, P. ja Hunhammar, S. 1999. Ecosystem services in urban areas. *Ecological Economics*. Vol. 29:2. p. 293-301. ISSN 0921-8009.

Breiman, L. 2001. Random forests. *Machine learning* 45: 5–32.

Campbell, J.B. ja Wynne, R.H. 2011. *Introduction to Remote Sensing Fifth Edition*. The Guilford Press, New York.

Ciesielski M., Sterenczak K. 2019. Accuracy of determining specific parameters of the urban forest using remote sensing. *iForest* 12: 498-510.

Daily, G. 1997. Natures services: societal dependence on natural ecosystems. Washington DC, USA: Island Press. 412 p. ISBN 1-55963-475-8.

Falkowski, M. J., Hudak, A. T., Crookston, N. L., Gessler, P. E., Uebler, E. H., Smith, A. M. 2010. Landscape-scale parameterization of a tree-level forest growth model: a knearest neighbor imputation approach incorporating LiDAR data. *Canadian Journal of Forest Research* 40: 184–199.

Gustavsson, R., Hermy, M., Konijnendijk, C., Steidle-Schwahn, A. 2005. Management of Urban Woodland and Parks—Searching for Creative and Sustainable Concepts. In:

Gómez-Baggethun, E., and Barton, D.N. 2013. Classifying and valuing ecosystem services for urban planning. *Ecological Economics* 86, 235–245.

Morgenroth J. ja Gomez C. 2014. Assessment of tree structure using a 3D image analysis technique - a proof of concept. *Urban Forestry and Urban Greening* 13: 198-203.

Holopainen, M., Kankare, V., Vastaranta, M., Liang, X., Lin, Y., Vaaja, M., Yu, X., Hyypä, J., Hyypä, H., Kaartinen, H., Kukko, A., Tanhuanpää, T. ja Alho, P. 2013a. Tree mapping using airborne, terrestrial and mobile laser scanning – A case study in a heterogeneous urban forest. *Urban Forestry & Urban Greening*, Vol, 12:4, p, 546-553, ISSN 1618-8667,

Holopainen, M., Hyypä, J. ja Vastaranta, M. 2013b. Laserkeilaus metsävarojen hallinnassa. 5 edn. Helsinki, Finland: Univ. of Helsinki. 75 p. ISBN 978-952-10-4533-2.

Hudak, A., Crookston, N., Evans, J., Hall, D., Falkowski, M. 2008. Nearest neighbor imputation of species-level, plot-scale forest structure attributes from LiDAR data. *Remote Sensing of Environment*, Volume 113, Issue 1, 15 January 2009, Pages 289-290

Hyypä, J. ja Inkinen, M. 1999. Detecting and estimating attributes for single trees using laser scanner. *The Photogrammetric Journal of Finland*. Vol. 16. p. 27-42. ISSN 0554-

Höfle B., Hollaus M., Hagenauer J. 2012. Urban vegetation detection using radiometrically calibrated small-footprint full-waveform airborne LiDAR data. *ISPR Journal of Photogrammetry and Remote Sensing* 67: 134-147.

Jaakkola, A., Hyypä, J., Kukko, A., Yu, X., Kaartinen, H., Lehtomäki, M. ja Lin, Y. 2010. A low-cost multi-sensoral mobile mapping system and its feasibility for tree measurements. *ISPRS Journal of Photogrammetry and Remote Sensing*. Vol. 65:6. p. 514-522. ISSN 0924-2716.

Kankare V., Liang X., Vastaranta M., Yu X., Holopainen M., Hyypä M. 2015. Diameter distribution estimation with laser scanning based multisource single tree inventory. *ISPRS Journal of Photogrammetry and Remote Sensing* 108: 161–171.

Konijnendijk, C. C., Nilsson, K., Randrup, T. B., Schipperijn, J. (eds.) *Urban Forests and Trees*. Springer, Berlin, Heidelberg. p. 369–397.

Lee J-H., Ko Y., McPherson E. 2016. The feasibility of remotely sensed data to estimate urban tree dimensions and biomass. *Urban Forestry and Urban Greening* 16: 208-220.

Lindberg, E. ja Holmgren, J. 2017. Individual Tree Crown Methods for 3D Data from Remote Sensing. *Current Forestry Reports*. Vol. 3:1. p. 19-31. ISSN 2198-6436.

Liu, J., Shen, J., Zhao, R., Xu, S. 2013. Extraction of individual tree crowns from airborne LiDAR data in human settlements. *Mathematical and Computer Modelling* 58: 524–535.

Lu, X., Guo, Q., Li, W. ja Flanagan, J. 2014. A bottom-up approach to segment individual deciduous trees using leaf-off lidar point cloud data. *ISPRS Journal of Photogrammetry and Remote Sensing*. Vol. 94. p. 1-12. ISSN 0924-2716.

Lyytimäki, J., Petersen, L. K., Normander, B., Bezák, P. 2008. Nature as a nuisance? Ecosystem services and disservices to urban lifestyle. *Environmental sciences* 5: 161–

172.

Lyytimäki, J., Sipilä, M. 2009. Hopping on one leg–The challenge of ecosystem disservices for urban green management. *Urban Forestry & Urban Greening* 8: 309–315.

Naesset, E. 1997. Determination of mean tree height of forest stands using airborne laser scanner data. *ISPRS Journal of Photogrammetry & Remote Sensing*. Vol. 52:2. p. 49-56. ISSN 0924-2716.

Nielsen, A. B., Östberg, J., Delshammar, T. 2014. Review of Urban Tree Inventory Methods Used to Collect Data at Single-Tree Level. *Arboriculture & Urban Forestry* 40: 96–111.

Nowak, D. J., Noble, M. H., Sisinni, S. M., Dwyer, J. F. 2001. People and trees: assessing the US urban forest resource. *Journal of Forestry* 99: 37–42.

Matasci, G., Coops, N.C., Williams, D.A. 2018. Mapping tree canopies in urban environments using airborne laser scanning (ALS): a Vancouver case study. *For. Ecosyst.*

Persson, Å., Holmgren, J. ja Söderman, U. (2002) Detecting and measuring individual trees using an airborne laser scanner. *Photogrammetric Engineering And Remote Sensing*. Vol. 68:9. p. 925-932. ISSN 0099-1112.

Plowright., Coops N., Eskelson B., Sheppard S., Aven N. 2016. Assessing urban tree condition using airborne light detection and ranging. *Urban Forestry and Urban Greening* 19: 140-150.

Rahman M ja Rashed T. 2015. Urban tree damage estimation using airborne laser scanner data and geographic information systems: an example from 2007 Oklahoma ice storm. *Urban Forestry and Urban Greening* 14: 562-572.

Rutzinger M., Pratihast A., Elberink S. 2011. Tree modeling from mobile laser scanning data-sets. *The Photogrammetric Record* 26 (135): 361-372.

Saarinen, N., Vastaranta, M., Kankare, V., Tanhuanpää, T., Holopainen, M., Hyypä, J., Hyypä H. 2014. Urban-tree-attribute update using multisource single-tree inventory Forests, 5 (5) (2014), pp. 1032-1052

Secord, J., Zakhor, A., 2007. Tree Detection in Urban Regions Using Aerial Lidar and Image Data. IEEE Geoscience and Remote Sensing Letters, 4(2), pp. 196-200.

Shrestha R., Wynne R. (2012) Estimating biophysical parameters of individual trees in an urban environment using small footprint discrete-return imaging Lidar. Remote Sensing 4: 484-508.

Tanhuanpää T., Kankare V., Vastaranta M., Saarinen N., Holopainen M. 2015. Monitoring downed coarse woody debris through appearance of canopy gaps in urban boreal forests with bitemporal ALS data. Urban Forestry & Urban Greening 14(4): 835–843.

Tanhuanpää, T. (2016) Developing laser scanning applications for mapping and monitoring single tree characteristics for the needs of urban forestry, Doctoral thesis, University of Helsinki, Helsinki, Finland.

Tanhuanpää, T., YU, X., Luoma, V., Saarinen, N., Raisio, J., Hyypä, J., Kumpula, T., Holopainen, M. 2019. Effect of canopy structure on the performance of tree mapping methods in urban parks. Urban Forestry & Urban Greening Volume 44, August 2019, 126441.

Tyrväinen, L., Pauleit, S., Seeland, K., de Vries, S. 2005. Benefits and uses of urban forests and trees. In: Konijnendijk, C. C., Nilsson, K., Randrup, T. B., Schipperijn, J. (eds.) Urban Forests and Trees. Springer, Berlin, Heidelberg. p. 81–114.

Vastaranta, M., Kantola T., Lyytikäinen-Saarenmaa, p., Holopainen M., Kankare, V., Wulder, M.A., Hyypä, J., Hyypä, H. 2013. Area-Based Mapping of Defoliation of Scots Pine Stands Using Airborne Scanning LiDAR. Remote Sensing 5(3):1220-1234.

Vosselman, G. ja Maas, H-G. (Eds.). 2010. Airborne and terrestrial laser scanning. CRC Press. 318 pp.

Wehr, A., Lohr, U. 1999. Airborne laser scanning—an introduction and overview. ISPRS Journal of Photogrammetry and Remote Sensing 54: 68–82.

Wu B., Yu B., Yue W., Shu S., Tan W., Hu Ch Huang Y., Wu J., Liu H. 2013. A voxel-based method for automated identification and morphological parameters estimation of individual street trees from mobile laser scanning data. Remote Sensing 5: 584-611.

Yao, W. ja Wei, Y. 2013. Detection of 3-D Individual Trees in Urban Areas by Combining Airborne LiDAR Data and Imagery. IEEE Geoscience and Remote Sensing Letters. Vol. 10:6. p. 1355-1359. ISSN 1545-598X.

Yu, X., Hyyppä, J., Vastaranta, M., Holopainen, M. ja Viitala, R. 2011. Predicting individual tree attributes from airborne laser point clouds based on the random forests 60 technique. ISPRS Journal of Photogrammetry and Remote Sensing. Vol. 66:1. p. 28-37. ISSN 0924-2716.

Zhang, C., Zhou, Y. ja Qiu, F. 2015. Individual Tree Segmentation from LiDAR Point Clouds for Urban Forest Inventory. Remote Sensing. Vol. 7:6. p. 7892-7913. ISSN 2072-4292.

LIITTEET

Liite 1. ALS-piirteet ja niiden selitteet.

ALS-piirre	Selite
Hmax	Korkeuspisteiden maksimiarvo
Hmean	Korkeuspisteiden keskiarvo
Hstd	Korkeuspisteiden keskihajonta
pene	Kasvillisuuskaikujen osuus kaikista kaiuista
CV	Korkeuspisteiden variaatiokerroin
Imax	Paluukaikujen intensiteetin maksimiarvo
Imean	Paluukaikujen intensiteetin keskiarvo
Imedian	Paluukaikujen intensiteetin maksimiarvo
h10-90	Korkeuspisteiden jakauman desiilit
p10-p99	Korkeuksien prosenttipisteet
P_no	Kasvillisuus pisteiden määrä latvussegmentin sisällä
area_chull	Latvussegmentin sisällä olevien pisteiden virittämä pinta-ala XY-tasossa
vol_alpha	Latvussegmentin sisällä olevien pisteiden virittämä tilavuus

Liite 2. ALS-piirteiden skaalattu merkittävyys läpimitan mallinnuksessa.

